

UNIVERSIDADE FEDERAL DO PARANÁ

LUIZ ALBERTO BORDIGNON

**IDENTIFICAÇÃO DE SEMENTES  
UTILIZANDO VISÃO  
COMPUTACIONAL**

Curitiba  
2015

UNIVERSIDADE FEDERAL DO PARANÁ

LUIZ ALBERTO BORDIGNON

**IDENTIFICAÇÃO DE SEMENTES  
UTILIZANDO VISÃO  
COMPUTACIONAL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração Sistemas Eletrônicos, Departamento de Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná, como parte das exigências para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Lucas Ferrari de Oliveira

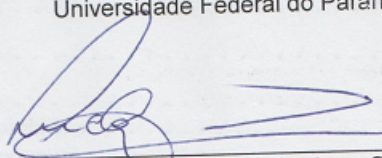
Curitiba  
2015

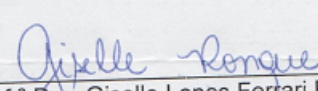
## TERMO DE APROVAÇÃO

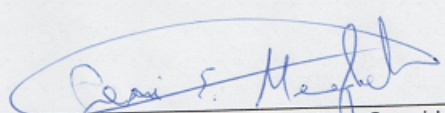
Luiz Alberto Bordignon

Identificação de sementes utilizando visão computacional

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Paraná.

  
Prof. Dr. Lucas Ferrari de Oliveira – Orientador  
Universidade Federal do Paraná

  
Prof.ª Dra. Giselle Lopes Ferrari Ronque – Convidado  
Universidade Federal do Paraná

  
Prof. Dr. Geri Eduardo Meneghello – Convidado  
Universidade Federal de Pelotas

Curitiba, 31 de agosto de 2015

# Sumário

<b>Lista de Figuras . . . . .</b>	<b>7</b>
<b>Lista de Tabelas . . . . .</b>	<b>9</b>
<b>Lista de Abreviaturas e Siglas . . . . .</b>	<b>10</b>
<b>Resumo . . . . .</b>	<b>11</b>
<b>Abstract . . . . .</b>	<b>12</b>
<b>1 Introdução . . . . .</b>	<b>1</b>
1.1 Definição do problema . . . . .	2
1.2 Hipóteses de pesquisa . . . . .	3
1.3 Objetivos . . . . .	3
1.3.1 Objetivo geral . . . . .	3
1.3.2 Objetivos específicos . . . . .	4
1.4 Contribuições . . . . .	4
1.5 Organização . . . . .	5
<b>2 Fundamentação teórica . . . . .</b>	<b>6</b>
2.1 Visão Computacional no Agronegócio . . . . .	6
2.2 Extração de características . . . . .	7
2.2.1 Haralick . . . . .	8
2.2.2 LBP . . . . .	10
2.2.3 CLBP . . . . .	11
2.2.4 Histograma . . . . .	12
2.2.5 LCP . . . . .	14
2.2.6 LPQ . . . . .	15
2.3 Classificação . . . . .	18
2.3.1 SVM . . . . .	18
2.3.2 RNA . . . . .	20
<b>3 Método proposto . . . . .</b>	<b>23</b>
3.1 Base de dados . . . . .	26
3.2 Criação de Blocos de Imagens . . . . .	31
3.2.1 Tamanho das sub-imagens . . . . .	33
3.2.2 Extração das sub-imagens . . . . .	35
3.3 Treinamento SVM . . . . .	36

3.3.1	<i>Kernel</i> . . . . .	37
3.3.2	Combinação de descritores . . . . .	38
3.4	Hierarquia . . . . .	38
3.4.1	Treinamento . . . . .	38
3.4.2	Classificação . . . . .	40
<b>4</b>	<b>Resultados e Discussão</b> . . . . .	<b>43</b>
4.1	Métrica de avaliação . . . . .	43
4.2	Definição do tipo de classificador . . . . .	44
4.3	Dimensão das sub-imagens . . . . .	45
4.4	Extração e análise das características . . . . .	47
4.4.1	Haralick . . . . .	47
4.4.2	LBP . . . . .	50
4.4.3	CLBP . . . . .	52
4.4.4	LCP . . . . .	54
4.4.5	LPQ . . . . .	57
4.4.6	Histograma . . . . .	58
4.4.7	Combinação dos Descritores . . . . .	62
4.5	SVM Hierárquico . . . . .	63
<b>5</b>	<b>Conclusão</b> . . . . .	<b>69</b>
	<b>Referências</b> . . . . .	<b>72</b>

## Lista de Figuras

Figura 2.1:	Processo de construção de um código LBP . . . . .	11
Figura 2.2:	Representação do histograma de imagem de feijão, canola e milho. . . . .	13
Figura 2.3:	Esquema do modelo de extração de textura LCP. . . . .	15
Figura 2.4:	Exemplo de SVM com duas classes. . . . .	19
Figura 3.1:	Método proposto para classificação de sementes. . . . .	24
Figura 3.2:	Modelo de hierarquia utilizado. . . . .	25
Figura 3.3:	(a) Copo para colocar sementes, (b) dispositivo fixador da câmera e (c) câmera fotográfica. . . . .	26
Figura 3.4:	Dispositivo fixador da câmera fotográfica. . . . .	27
Figura 3.5:	Ilustração do dispositivo. . . . .	28
Figura 3.6:	Em a) é mostrada uma imagem sem o revestimento e em b) a mesma amostra no copo com o revestimento. . . . .	28
Figura 3.7:	(a) - Detalhe da membrana (b) Copo revestido (c) Visão geral do aparato. . . . .	29
Figura 3.8:	Exemplo de imagens com a utilização de película e revestimento do copo. . . . .	29
Figura 3.9:	Exemplo de imagens obtidas. Em a) Canola, b) Cevada, c) Cevadinha, d) Ervilha Partida, e) Feijão Cavallo, f) Gergelim, g) Linhaça, h) Milho, i) Quinoa, j) Ervilha Inteira, k) Lentilha, l) Soja, m) Torta de Algodão. . . . .	31
Figura 3.10:	Representação do modelo que fragmentação das imagens. . . . .	32
Figura 3.11:	Representação do modelo que fragmentação das imagens da espécie <i>Canola</i> . . . . .	34
Figura 3.12:	Representação do modelo que fragmentação das imagens da espécie <i>Soja</i> . . . . .	34
Figura 3.13:	Limites utilizados na região de interesse para extração das sub-imagens. . . . .	35
Figura 3.14:	Descrição do método proposto. . . . .	41
Figura 4.1:	Desempenho dos classificadores RNA e SVM. . . . .	44
Figura 4.2:	Comparação da média e desvio padrão entre todos os tamanhos testados: 32x32, 37x37, 48x48, 64x64, 96x96 e 192x192. . . . .	46
Figura 4.3:	Resultado da classificação para cada classe nos tamanhos 96x96 e 192x192. . . . .	46
Figura 4.4:	Resultados do histograma dos descritores de Haralick aplicados as sub-imagens de Canola, Soja e Feijão Cavallo. . . . .	48

Figura 4.5: Representação do LBP para uma matriz 3x3 com raio 1. . . . .	50
Figura 4.6: Um exemplo do Histograma dos códigos LBP em imagens de canola, soja e feijão cavalo. . . . .	51
Figura 4.7: Comparação entre os descritores de Haralick e LBP. . . . .	51
Figura 4.8: Histograma dos códigos CLBP em imagens de canola, soja e feijão cavalo. . . . .	53
Figura 4.9: Comparação entre os descritores de LBP e CLBP. . . . .	54
Figura 4.10: Exemplo de Histograma dos códigos LCP em imagens de canola, soja e feijão cavalo. . . . .	55
Figura 4.11: Comparação entre os descritores de LBP, CLBP e LCP. . . . .	56
Figura 4.12: Imagens capturadas da classe gergelim (a) e (b). . . . .	57
Figura 4.13: Histograma dos códigos LPQ em imagens de canola, soja e feijão cavalo de tamanho 96x96. . . . .	58
Figura 4.14: Comparação entre os descritores de CLBP e LPQ. . . . .	58
Figura 4.15: Histograma das sementes de gergelim e feijão cavalo. . . . .	60
Figura 4.16: Comparação entre todos os métodos testados individualmente neste trabalho com imagens 192x192 <i>pixels</i> . . . . .	61
Figura 4.17: Matriz de confusão dos resultados do SVM hierárquico utilizando imagens 192x192 <i>pixels</i> . . . . .	67
Figura 4.18: Diferenças entre as imagens das safras em (a) 2013 e em (b) 2014 .	68
Figura 5.1: Comparação entre as classes Soja (a) e Ervilha inteira (b). . . . .	69

## Lista de Tabelas

Tabela 2.1: Resumo dos descritores usados neste trabalho. . . . .	7
Tabela 2.2: Descrição dos descritores de Haralick utilizados. . . . .	9
Tabela 3.1: Descrição dos tipos de sementes e suas correspondentes quantidades.	30
Tabela 3.2: Tamanhos e quantidades de sub-imagens geradas. . . . .	36
Tabela 3.3: Combinações realizadas com diferentes tipos de descritores. . . . .	39
Tabela 3.4: Descrição do processo de hierarquia. . . . .	42
Tabela 4.1: Resultados obtidos usando descritores de Haralick com SVM <i>kernel</i> RBF. . . . .	49
Tabela 4.2: Resultados obtidos utilizando os códigos LBP com SVM <i>kernel</i> QUADRATIC. . . . .	52
Tabela 4.3: Resultados obtidos utilizando os códigos CLBP com SVM <i>kernel</i> POLYNOMIAL. . . . .	54
Tabela 4.4: Resultados obtidos utilizando os códigos LCP com SVM <i>kernel</i> QUADRATIC. . . . .	56
Tabela 4.5: Resultados obtidos utilizando os códigos LPQ com SVM <i>kernel</i> QUADRATIC. . . . .	59
Tabela 4.6: Resultados obtidos utilizando Histograma com SVM <i>kernel</i> QUADRATIC. . . . .	61
Tabela 4.7: Resultados individual dos descritores ordenados do melhor resultado para o pior. . . . .	63
Tabela 4.8: Resultados geral das combinações testadas. . . . .	64
Tabela 4.9: Classes ordenadas de acordo com o desempenho obtido na saída do SVM sem hierarquia. . . . .	65
Tabela 4.10: Desempenho das classes obtido na saída do SVM com hierarquia.	66



## Lista de Abreviaturas e Siglas

ISO	International Organization for Standardization
Embrapa	Empresa Brasileira de Pesquisa Agropecuária
LCP	Local Configuration Pattern
LPQ	Local Phase Quantization
CLBP	Complete Local Binary Pattern
LBP	Local Binary Pattern
SVM	Support Vector Machine
RNA	Redes Neurais Artificiais
DFT	Discrete Fourier Transform
STFT	Short Term Fourier Transform
SVD	Singular Value Decomposition
ffn	feed forward network
RBF	Gaussian Radial Basis
MLP	Multilayer Perceptron
DN	digital numbers

## Resumo

Existem muitos sistemas computacionais aplicados a área do agronegócio, que visam melhorar a produtividade, qualidade dos produtos, reduzir desperdícios e auxiliar na tomada de decisões. Da mesma forma medidores de umidade vem se tornando cada vez mais tecnológicos com o passar do tempo e, neste caso, tornar o processo mais automático auxilia na redução de erros e aumenta a produtividade. Em relação aos avanços tecnológicos uma das áreas que vem se destacando no setor é a de visão computacional, que ao longo do tempo tem se tornando mais acessível como tecnologia. Visão computacional é um conjunto de métodos e técnicas utilizadas para interpretar imagens, auxiliando na tomada de decisões, a partir de reconhecimento de padrões. Visando contribuir com esse cenário de desenvolvimento tecnológico no setor do agronegócio, o presente trabalho apresenta um método automático de classificação de sementes utilizando visão computacional. Um conjunto de dados foi criado para o treinamento e testes do método proposto, utilizando 13 diferentes tipos de sementes. A metodologia testada utilizou 6 técnicas de descritores de características (LPQ, LBP, LCP, CLBP, Haralick e Histograma) que foram arranjadas em um vetor de treinamento e de testes do classificador. A avaliação individual e combinações dos descritores também foram alvo de estudo neste trabalho. Também foram testados 2 tipos de classificadores, SVM e RNA. Os resultados obtidos com o método mostraram-se promissores, em 12 dos 13 tipos de sementes testadas a taxa de acerto foi igual ou maior que 85%, ficando abaixo desta marca apenas a classe de *Soja*.

**Palavras-chave:** Identificação automática, Visão computacional, Identificação de sementes.

# Abstract

Many are the computer systems applied to agribusiness area, aimed at improving productivity, products quality, reduce waste and assist in making decisions. Following this trend of technological advances, a prominent area for the sector is the computer vision, which over time has become more accessible as technology. Computer vision is a set of methods and techniques used to interpret images, assisting in decision-making, of pattern recognition. Likewise, moisture measurers have become increasingly technological over time, which make the automatic process reduce errors and increases productivity. An important part of this moisture reading process is to select the type of seed that will be sampled. To contribute to this scenario of technological development, this current work presents an automatic classification method using computer vision. A dataset was created for training and testing of the method proposed here, using 13 different types of seeds. The method used six features descriptors techniques to compose the training and tests vector (LPQ, LBP, LCP, CLBP, Haralick, Histogram and Gabor). Individual assessment and descriptors combinations were also the subject of study in this work. We also tested two types of classifiers, SVM and RNA. The results obtained with the method shown promise in 12 of the 13 kinds of seeds tested, hit rate was equal to or greater than 85%, below this mark of the soy class.

**Keywords:** Automatic classification, Computer vision, Classification of seeds.

# 1 Introdução

O Brasil é um dos maiores produtores de grãos do mundo, no ano de 2014 teve a maior safra de sua história, e os fatores que influenciam este crescimento são: tecnologia, mecanização, crédito, relações de troca, melhoria na organização e na gestão dos negócios (OLIVEIRA, 2014). Conforme mostra o estudo realizado pelo Ipea (Instituto de Pesquisa Econômica Aplicada) o principal fator para o aumento da produtividade é a tecnologia, que em instituições de pesquisa vem se desenvolvendo, como por exemplo a Empresa Brasileira de Pesquisa Agropecuária (Embrapa) (GASQUES et al., 2004).

Nesse cenário, visando uma contribuição para o setor de comércio de sementes o processo de medição do teor de umidade de grãos tem se tornado cada vez mais automático. A importância de mensurar com precisão a umidade das sementes na hora da comercialização está associado ao seu valor final de venda, sementes muito secas tem seu valor de mercado reduzido devido a sua baixa produtividade de óleo e derivados, já uma semente muito úmida necessita de cuidados especiais para sua armazenagem o que acarreta custos, logo seu preço também é reduzido. Existem duas normas ISO (*International Organization for Standardization*) que regulamentam parâmetros e procedimentos para determinar o teor de umidade dos grãos, são elas: ISO 711:1985 *Cereals and cereal products – Determination of moisture content* e a ISO 712:2009 *Cereals and cereal products – Determination of moisture content*. As normas especificam um método de referência para determinar o teor de umidade e a faixa de valores ideal para cada tipo de grão. As normas também detalham os processos e os parâmetros necessários a serem cumpridos para obter um padrão de medida (ISO 711, 1985) (ISO 712, 2009).

Uma parte do processo de medir o teor de umidade de grãos é a seleção da espécie de semente a ser amostrada. Nos métodos convencionais a seleção do tipo do grão é feita manualmente pelo operador de forma visual. Esta seleção está sujeita a erros, visto que depende da experiência do operador e do seu estado físico e mental. Para minimizar o problema nessa fase do processo, métodos automatizados podem ser utilizados, porém detalhes na captura das imagens e nos algoritmos de segmentação, extração de características e classificação precisam ser estudados.

A proposta deste trabalho foi criar uma base de dados para aplicar técnicas de visão computacional para a classificação de algumas variedades de sementes. Uma base de dados foi criada para esse propósito, essa base foi dividida em duas partes, sementes da safra de 2013 e sementes da safra de 2014. A importância de ter duas safras diferentes é testar a robustez do método proposto, usando imagens de uma safra para treinamento e a outra para testes. O método testou diferentes técnicas de extração de características, buscando explorar as diferentes texturas das imagens, para tal foram aplicadas nesse conjunto de dados, as seguintes técnicas: Haralick, LCP (*Local Configuration Pattern*), LPQ (*Local Phase Quantization*), CLBP (*Completed Local Binary Pattern*), LBP (*Local Binary Pattern*) e Histograma. E dois modelos de classificadores, SVM (Máquina de Vetores de Suporte) e RNA (Redes neurais artificiais). Utilizando SVM como classificador, foram testados duas abordagens diferentes, SVM um-contra-todos e SVM hierárquico.

## 1.1 Definição do problema

Existem vários trabalhos relacionados a classificação de padrões utilizando visão computacional, principalmente nas áreas de reconhecimento facial, classificação de patologias na área médica e classificação de objetos na área industrial. A classificação de sementes, normalmente ocorre em um ambiente controlado, com as

sementes separadas entre si, e arranjadas de forma específica por um indivíduo, para atender a requisitos mínimos dos algoritmos desenvolvidos nas pesquisas. Nossa proposta é identificar algumas variedades de sementes de forma automática, onde não há controle mínimo na forma como as sementes são alocadas no dispositivo de aquisição. Outra característica importante desta pesquisa, foi a criação de uma base de dados própria, onde foram utilizados duas safras diferentes para a aquisição das imagens.

## **1.2 Hipóteses de pesquisa**

A hipótese a ser verificada neste trabalho é a de utilizar as técnicas de reconhecimento de padrões para classificar 13 tipos diferentes de sementes, utilizando a combinação de descritores de características e combinação de classificadores. A técnica deve ser robusta a variações na qualidade das imagens obtidas (borramentos, foco, iluminação), assim como nas variações entre as sementes de safras diferentes, que podem ter características distintas devido a condições variadas, como por exemplo, transporte, colheita, clima, etc.

## **1.3 Objetivos**

### **1.3.1 Objetivo geral**

O objetivo geral desta dissertação é a avaliação de um método capaz de classificar automaticamente algumas variedades de sementes, utilizando uma base de dados própria, adquirida especificamente para este trabalho. Assim como a avaliação de técnicas de extração de características, neste trabalho foram utilizadas

as técnicas: Haralick, LBP, CLBP, LCP, LPQ e Histograma. Cada técnica será avaliada individualmente, os melhores resultados serão combinados, somando as características mais discriminantes de cada extrator. Também serão empregados os modelos de classificadores SVM e RNA, que serão avaliados individualmente.

### 1.3.2 Objetivos específicos

- Criação de um conjunto de dados;
- Divisão das imagens obtidas em sub-imagens, para aumentar o conjunto de dados;
- Implementação e análise de técnicas de extratores de características;
- Implementação e análise de modelos de classificadores;
- Avaliação de desempenhos das técnicas de extração de características e classificadores aplicadas nos diferentes tamanhos de sub-imagens geradas;
- Avaliação de desempenhos com a combinação dos descritores de características;
- Desenvolvimento de um modelo hierárquico utilizando SVM;
- Testes e avaliação dos resultados.

## 1.4 Contribuições

Em face da inexistência de uma base de dados compatível com o objetivo deste trabalho, é apresentada como contribuição uma base de dados contendo 13 tipos diferentes de sementes, separadas em duas safras (339 imagens) e também sub-imagens geradas a partir dessa base com tamanhos de 32x32 (46656 imagens),

37x37 (33900 imagens), 48x48 (21696 imagens), 64x64 (12204 imagens), 96x96 (5424 imagens) e 192x192 (1356 imagens) *pixels*. Assim como um estudo que relaciona o desempenho da combinação de descritores de características aplicados a classificação de sementes. E o desenvolvimento de um modelo hierárquico para classificação, utilizando o classificador SVM.

## 1.5 Organização

Este trabalho está dividido em 5 seções principais: *Introdução*, em que é descrito uma breve contextualização do problema, hipótese de pesquisa e objetivos do trabalho. Na seção *Fundamentação teórica* são mostrados as técnicas de extração de características, e modelos de classificadores que são abordados neste trabalho. A seção *Método proposto* apresenta os detalhes na construção do modelo desenvolvido para realização dos experimentos. A seção *Resultados* mostra os resultados obtidos com os experimentos. Por fim a seção *Conclusão* encerra o trabalho com um resumo geral da proposta desenvolvida, uma discussão dos resultados obtidos e possíveis trabalho futuros.



## 2 Fundamentação teórica

Existem muitos trabalhos na literatura referentes a classificação utilizando visão computacional, em várias áreas de conhecimento. Na área de sementes, muitas pesquisas estão ligadas a identificação e classificação de ervas daninhas em alguns tipos de culturas, como por exemplo, o milho (ORLANDO, 2003). Outras pesquisas avaliam a qualidade das sementes, como trigo, milho e soja (RIBEIRO, 2015). E algumas pesquisas trabalham na identificação e classificação de patologias, ou anomalias em algumas variedades de sementes, principalmente na cultura do milho (BURKS et al., 2000). Poucos trabalhos dedicam-se especificamente a classificação de variedades de sementes. Neste capítulo serão abordados métodos utilizados na extração de características e classificação em diversas abordagens.

### 2.1 Visão Computacional no Agronegócio

O aumento do uso da tecnologia em equipamentos utilizados no agronegócio, faz com que a qualidade e produtividade dos produtos aumente também. Dessa forma a utilização de tecnologia torna-se um diferencial, ganhando cada vez mais espaço nesse setor importante da economia (ARAÚJO, 2005). Muitos sistemas e aplicações são criados para aumentar a performance no campo, buscando aumento na produção, redução de desperdícios, e sistemas que auxiliam na tomada de decisão. Seguindo esse avanço tecnológico, a visão computacional é uma área da ciência que busca auxiliar o homem na tomada de decisões, tornando alguns processos mais rápidos e menos cansativos. Podemos de forma simplificada definir visão computacional como um conjunto de técnicas e métodos de identificação e extração de características, processamento e análise de uma imagem. (BORTH et al., 2014).

## 2.2 Extração de características

O processo de extração de características fornece informações para a etapa de classificação. Com base em características obtidas de objetos, diversas informações podem ser adquiridas, como por exemplo, histogramas, forma, tamanho, textura, frequência, etc (QUEIROZ; GOMES, 2006). Essas informações são parte importante do processo de classificação, pois quanto mais discriminantes forem as características obtidas, melhor é tomada de decisão do classificador. Trabalhos como FILHO et al. (2014) e HANUSIAK et al. (2010) mostram que combinações de características podem ser complementares auxiliando na tomada de decisão dos classificadores.

Neste trabalho foram utilizados 6 tipos de extratores de características, que fazem análises estatísticas, estruturais e espectrais. Tais tipos foram escolhidos devido ao grande uso em trabalhos relacionados na literatura (ORLANDO, 2003) (BARBOSA, 2009) (FILHO et al., 2014). A Tabela 2.1 apresenta os descritores utilizados neste trabalho e a quantidade de informação (dimensão) de cada um deles.

Tabela 2.1: Resumo dos descritores usados neste trabalho.

ID	Nome	Dimensão
1	Haralick	13
2	CLBP	118
3	LBP	59
4	Histograma	256
5	LCP	81
6	LPQ	256

### 2.2.1 Haralick

Descritores de Haralick são amplamente utilizados para representar estatística de um conjunto de *pixels* de uma imagem, e na literatura são utilizados como meio de caracterizar textura. Podemos definir este descritor como a ocorrência da probabilidade de níveis de cinza numa relação espacial em uma imagem. Essa relação é definida por uma distância e um ângulo. Usualmente a relação mais relevante ocorre em distâncias curtas, onde o valor para  $d$  é mantido pequeno e expressa na forma  $(d, \Theta)$ , com  $d$  representando a distância linear em *pixels*, e  $\Theta$  o ângulo entre eles (HARALICK; SHANMUGAM; DINSTEN, 1973). A equação 2.1 demonstra a contagem da ocorrência dos *pixels* em uma imagem  $f$ :

$$P(i, j, d, \Theta) = ((k, l), (m, n)) \in f | k - m = 0, |l - n| = d, f(k, l) = i, f(m, n) = j \quad (2.1)$$

onde  $(k, l)$  e  $(m, n)$  são as coordenadas dos *pixels* em questão e  $\Theta$  representa o ângulo que define a direção.

Neste trabalho foram utilizados 13 descritores propostos por Haralick, eles estão descritos na Tabela 2.2.

As principais características utilizadas são a energia, entropia, variância, homogeneidade, dissimilaridade e medidas de correlação. A energia (equação 2.2), também conhecida por segundo momento angular, permite identificar o grau de homogeneidade das medidas de distância.

$$Energia = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} P(i, j)^2 \quad (2.2)$$

A entropia (equação 2.3) mede o nível de desordem das distâncias. A entropia é calculada utilizando a soma das linhas da matriz de probabilidade e aplicando-se

Tabela 2.2: Descrição dos descritores de Haralick utilizados.

ID	Descritor
1	Energia
2	Correlação
3	Inércia
4	Entropia
5	Momento de diferença inversa
6	Soma da média
7	Soma da variação
8	Soma da entropia
9	Diferença da média
10	Diferença da variação
11	Diferença da entropia
12	Medida de correlação 1
13	Medida de correlação 2

a fórmula da entropia para estas probabilidades

$$Entropia = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} P(i, j) \log(P(i, j)) \quad (2.3)$$

A variância (equação 2.4) mede variação de uma distância para outra.

$$Variancia = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} P(i, j)(i - j)^2 \quad (2.4)$$

A homogeneidade (equação 2.5) indica se os valores entre as distâncias são constantes ou não.

$$Homogeneidade = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} \frac{1}{1 + (i - j)^2} P(i, j) \quad (2.5)$$

O cálculo da dissimilaridade (equação 2.6) é parecido com o da variância,

porém o crescimento dos pesos não é exponencial e sim linear.

$$Dissimilaridade = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} |i - j| P(i, j) \quad (2.6)$$

O descritor foi configurado utilizando 4 ângulos diferentes ( $\Theta = 0, 45, 90, 135$ ) e distância  $d = 1$ . O vetor de características resultante é composto por 13 atributos.

### 2.2.2 LBP

*Local binary pattern* (LBP) é um método de descrição de textura que vem apresentando um bom desempenho em diversas áreas de pesquisa (FILHO et al., 2014). Essencialmente o LBP é a comparação do ponto central de uma região delimitada (normalmente 3x3) com seus vizinhos, então é gerado um código para substituir o valor do ponto central (OJALA; PIETIKAINEN; MAENPAA, 2002). Esse processo depende de um limiar, de acordo com a equação:

$$s|x| = \begin{cases} 1, & Px > P \\ 0, & \text{caso contrário.} \end{cases} \quad (2.7)$$

O LBP original proposto inicialmente por Ojala et al. consiste em limiarizar os pontos vizinhos do ponto central, e como resultado deste processo gerar um código em formato binário. No exemplo da Figura 2.1 com uma região de vizinhos de 3x3 o ponto central é excedido 4 vezes resultado no código binário 11011000 (OJALA; PIETIKÄINEN; HARWOOD, 1996).

Em nosso trabalho foi configurado um LBP (8, 1) que relaciona, os 8 mais próximos vizinhos do *pixel* central, que gera um vetor de 59 características.

105	102	69
98	101	3
102	110	54

1	1	0
0		0
1	1	0

Figura 2.1: Processo de construção de um código LBP

### 2.2.3 CLBP

Proposto inicialmente por Guo e Zhang em 2010 (?), tem como função principal analisar a informação do *pixel* central em relação aos seus vizinhos assim como o LBP descrito anteriormente, porém este método contempla também a magnitude e a intensidade do *pixel* central em relação a imagem completa. A magnitude da distância tem como objetivo tornar o método mais discriminante e é representada pela seguinte equação:

$$s|x| = |Gp - Gc| \quad (2.8)$$

onde  $Gc$  é o *pixel* central e  $s|x|$  é a componente de magnitude. O método CLBP retorna 3 operadores:

- CLBP-S: componente de sinal da diferença
- CLBP-M: componente de magnitude
- CLBP-C: intensidade do *pixel* central em relação a imagem

O CLBP-S representa o método LBP convencional descrito na seção anterior.

O CLBP-M é representado pela equação 3:

$$CLBP - M(P, R) = \sum_{p=0}^{P-1} S(mp - c)2^p \quad (2.9)$$

Onde,  $c$  corresponde à média dos valores absolutos das diferenças entre um *pixel* e seu vizinho.

O operador CLBPc pode ser representado pela equação:

$$CLBPc(P, R) = S(Gc - T1) \quad (2.10)$$

Onde, onde  $Gc$  é o *pixel* central e  $T1$  corresponde à média dos valores de nível de cinza de todos os *pixels* da imagem. Em nosso trabalho os três operadores foram combinados (concatenados os vetores individuais) para obter o vetor de características.

#### 2.2.4 Histograma

Histogramas representam a distribuição de intensidades dos valores de cada *pixel* da imagem. Ao observar uma imagem tem-se uma noção sobre as características da mesma. Conforme Silva *et al.*, em processamento de imagens, trabalha-se sempre com tons de cinza (onde um número representa a intensidade do tom) que são atribuídos aos *pixels* da imagem (SILVA, 2001). Dessa forma o histograma é uma forma de representar a distribuição dos níveis de cinza de uma imagem. Os valores de níveis de cinza em nosso trabalho são de 8 bits, então variam de 0 a 255. Na figura 2.2 são apresentadas imagens utilizadas neste trabalho, as sementes são: Feijão Cavallo, Canola e Milho com seus respectivos histogramas.

O histograma normalizado pode ser representado pela seguinte equação:

$$P_y(r_k) = \frac{n_k}{n} \quad (2.11)$$

onde,  $0 \leq r_k \leq 1$ ;

$k = 0, 1, \dots, L - 1$ , onde  $L$  é o número máximo de níveis de cinza da imagem;

$n$  = número total de *pixel* da imagem;

$n_k$  = número de *pixels* que corresponde a  $k$ ;

$P_r(r_k)$  = probabilidade do  $K$ -esimo nível de cinza;

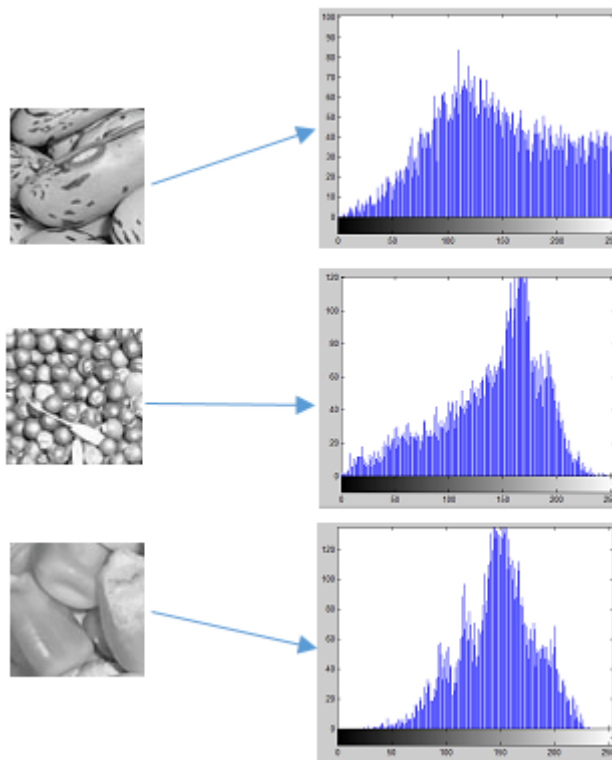


Figura 2.2: Representação do histograma de imagem de feijão, canola e milho.



### 2.2.5 LCP

*Local configuration pattern* (LCP) decompõe as informações da imagem em dois níveis, 1) informação sobre a estrutura local, 2) informação de configuração microscópica e relações de interação ponto a ponto, conforme mostra a figura 2.3. Para estruturas de informações locais o método utiliza LBP para extração de características, enquanto um modelo de configuração microscópica é utilizado para extrair informações de configuração microscópica (GUO; ZHAO; PIETIKÄINEN, 2011).

Para um modelo de configuração microscópica, é estimado pesos para cada padrão, associado com a intensidade dos *pixels* vizinhos, para reconstruir linearmente a intensidade do *pixel* central, expresso por:

$$E(a_0, \dots, a_{p-1}) = |g_c - \sum_{i=0}^{P-1} a_i g_i|. \quad (2.12)$$

Onde  $g_c$  e  $g_i$  são valores de intensidade do *pixel* central e os pixels vizinhos de um particular tipo de padrão respectivamente,  $a_i (i = 0, \dots, P-1)$  são parâmetros de ponderação associado com  $g_i$ , e  $E(a_0, \dots, a_p - 1)$  é o erro de reconstrução sobre parâmetros do modelo  $a_i (i = 0, \dots, P-1)$ . Para minimizar o erro de reconstrução para cada padrão, os parâmetros ideais são determinados pela estimativa dos mínimos quadrados. Os códigos são calculados de acordo com a equação utilizada no método LBP representada por:

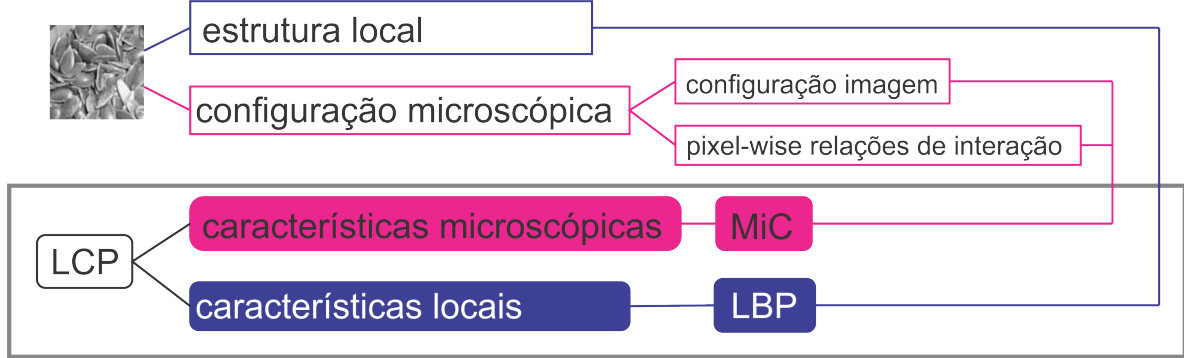
$$LBP(P, R) = \sum_{i=0}^{P-1} u(g_i - g_c) 2^i, \quad (2.13)$$

Onde  $P$  é número de vizinhos e  $R$  é o raio da vizinhança,  $g_i$  mostra o valor

da intensidade do *pixel* vizinho  $i$  ( $i = 0, \dots, P - 1$ ),  $g_c$  é a intensidade do valor do *pixel* central, e  $u(x)$  é representada por:

$$u(x) = \begin{cases} 1 & , x \geq 0, \\ 0 & \text{caso contrário.} \end{cases} \quad (2.14)$$

Figura 2.3: Esquema do modelo de extração de textura LCP.



Fonte (O Autor, 2015)

### 2.2.6 LPQ

Mesmo em ambientes controlados para a aquisição, degradações podem ocorrer devido ao movimento no instante da captura, ou a imagem ficar fora de foco. Essas degradações podem limitar a aplicação de métodos de texturas (OJANSIVU; HEIKKILÄ, 2008).

*Local phase quantization* (LPQ) é um método bastante robusto em imagens desfocadas, pois utiliza o método de invariância ao borrimento do espectro de fase de Fourier para classificar texturas, para isso utiliza a transformada discreta 2D de Fourier (*Discrete Fourier Transform* - DFT) processada sobre uma janela local para cada *pixel* da imagem (OJANSIVU; RAHTU; HEIKKILA, 2008).

A proposta deste descritor é representar a textura dos *pixels* de uma imagem, a partir de cada *pixel*  $x$  de uma imagem  $N$ , considerando uma vizinhança  $Vx(MxM)$ , utilizando a transformada de Fourier de curto termo (*ShortTerm Fourier Transform* - STFT), conforme equação 2.15.

$$\hat{f}_{u_i}(x) = (f \times \phi_{u_i})x \quad (2.15)$$

Sendo o filtro  $\phi_{u_i}$  dado pela equação 2.16:

$$\phi_{u_i} = e^{-j2\Pi u_i^T y} |y \in Z^2 ||y||_\infty \leq r \quad (2.16)$$

onde,  $r = (m - 1)/2$ , e  $u_i$  é o vetor base na 2D-DFT na frequência  $i$ .

Somente quatro coeficientes complexos são considerados, correspondendo a frequência 2D, especialmente  $u_1 = [a, 0]^T$ ,  $u_2 = [0, a]^T$ ,  $u_3 = [a, a]^T$  e  $u_4 = [a - a]^T$ , onde  $a = 1/m$ . Podemos representar a equação 2.15 como:

$$\hat{f}_{u_i}(x) = w_{u_i}^T f(x) \quad (2.17)$$

Onde  $w$  é o vetor base da DFT na frequência  $u$  e  $f(x)$  constitui um vetor dos  $m^2$  *pixels* da vizinhança  $Vx$ . Baseado na propriedade que a magnitude possui a maior parte das informações na transformada de Fourier, um processo de redução de dimensionalidade é realizado. Sendo  $F = [f(x_1), f(x_2), \dots, f(x_{n^2})]$  e a matriz que compreende a vizinhança de todos os *pixels* da imagem sendo  $m^2 \times N^2$  e  $\phi = [\phi_R, \phi_I]^T$  em que  $\phi_R = \text{Re}[\phi_u1, \phi_u2, \phi_u3, \phi_u4]$  representa a parte real, e  $\phi_I = \text{Im}[\phi_u1, \phi_u2, \phi_u3, \phi_u4]$  representa sua parte imaginária. Temos então a matriz

de transformação STFT  $8 \times N^2$  dada por  $\hat{F} = wF$ . Segundo os autores Ojansivu e Heikkilä a função  $f(x)$  é o resultado de um processo de primeira ordem de Markov, onde o coeficiente de correlação entre *pixels* adjacentes  $x_i$  e  $x_j$  está relacionado exponencialmente com sua distância  $L^2$ . Uma matriz de covariância  $C(m^2 \times m^2)$  é definida para o vetor  $\vec{f}$ , representada pela equação 2.18.

$$C_{i,j} = \sigma^{\|x_i - x_j\|} \quad (2.18)$$

Onde  $\|.\|$  denomina o modelo  $L_2$ , e a matriz de covariância dos coeficientes de Fourier pode ser obtido a partir de:

$$D = wCw^T \quad (2.19)$$

Uma vez que  $D$  não é uma matriz diagonal, isto é, os coeficientes são correlacionados, eles podem ser descorrelacionados usando a transformação  $E = V^T \hat{F}$  onde  $V$  é uma matriz ortogonal derivada do valor de decomposição singular (*Singular Value Decomposition* SVD) da matriz  $D$  que é:

$$D' = V^T D V \quad (2.20)$$

Os coeficientes são então quantizados usando:

$$q_{i,j} = \begin{cases} 1 & \text{se } e_{i,j} \geq 0, \\ 0 & \text{caso contrário.} \end{cases} \quad (2.21)$$

Onde  $e_{i,j}$  são componentes de  $E$ . Os coeficientes quantizados são então representados como valores inteiros entre 0-255 usando codificação binária

$$b_j = \sum_{i=0}^7 q_{i,j} 2^i \quad (2.22)$$

Por fim, um histograma dos valores inteiros de todas as posições da imagem é formado, e usado como vetor de características de 256 dimensões.

## 2.3 Classificação

O processo de classificação de objetos, tem como principal fator identificar um padrão num conjunto de atributos. Cada imagem é formada por um padrão de atributos. Sendo assim, cabe ao classificador por meio de modelagens matemáticas, estatísticas e relacionais identificar imagens similares, que contenham uma ou mais características semelhantes, e agrupá-las numa mesma classe. Parte importante desse processo é a extração de características, quanto mais discriminante for as características entre duas classes, menos complexa é a tomada de decisão do classificador.

### 2.3.1 SVM

Máquina de vetores de suporte (SVM) é uma técnica de aprendizagem que vem sendo utilizada amplamente em problemas de classificação onde envolvem grande volume de dados. De forma simplificada o funcionamento do SVM consiste em separar dois conjuntos de dados, os pontos que tem a menor distância entre esses

dados são chamados de vetor de suporte. Seus resultados são comparáveis e muitas vezes superiores a outros métodos como por exemplo, Redes Neurais Artificiais (LORENA; CARVALHO, 2007). Na figura 2.4 mostra um exemplo simples de um SVM de duas classes.




Figura 2.4: Exemplo de SVM com duas classes.

Na figura 2.4 os círculos vermelhos e o retângulo vermelho são os vetores de suporte, as linhas  $P1$  e  $P2$  formam o hiperplano, e a linha em negrito representa a linha de separação ótima. Algumas características tornam esse método atrativo ao nosso trabalho, como por exemplo: (i) Capacidade de generalização devido à sua eficiência na classificação de dados que não pertencem ao conjunto utilizado no treinamento; (ii) Robusta para classificação em grandes dimensões, como imagens; (iii) Robustez matemática.

### 2.3.1.1 Multiclasses

SVMs por definição operam com problemas de duas classes, já que seu algoritmo separa dois conjuntos de dados para formar um vetor de suporte separado por um hiperplano. Porém existem métodos para contornar essa limitação separando o problema em múltiplos problemas binários. Basicamente existem dois métodos para resolver SVMs multiclasses: um-contra-todos (one-versus-all) e um-contra-um

(one-versus-one).

Na estratégia um-contra-todos é criado  $N$  SVMs, onde  $N$  é o número total de classes do problema. Para o treinamento nesse modelo, uma classe é separada das demais, e todas as outras são consideradas a outra classe, seguindo essa lógica todas as classes são separadas e treinadas contra as outras até que chegue a última classe do problema. No final o SVM que tiver o melhor resultado de classificação é definido como saída.

O método um-contra-um o SVM faz a classificação entre duas classes presentes no problema. Neste caso os SVMs treinados são formados por duas classes. Assim para um novo padrão a ser classificado ele passará por todos os SVMs treinados, e o qual tiver melhor classificação será considerado pertencente a esta classe.

Em nosso trabalho foram utilizadas ambas as técnicas para classificação, e também uma estratégia que usa partes dos dois métodos descritos acima para formar um SVM hierárquico.

### 2.3.2 RNA

As Redes Neurais Artificiais são sistemas não lineares baseados na funcionalidade dos neurônios biológicos, e são utilizadas principalmente em problemas de classificação, reconhecimento de padrões e otimização na precisão de sistemas complexos. Constituídas de diversas unidades computacionais paralelas, interconectadas parcialmente ou totalmente, em que cada uma dessas unidades efetua operações simples, e passam seus resultados para outros neurônios vizinhos que tenham conexão. As RNAs dependem de um processo de treinamento, que as tornam capazes que responder a estímulos de entrada. A partir desse aprendizado, a rede se torna ca-

paz de identificar padrões, desta maneira consegue classificar uma entrada em uma determinada classe de saída (BRUMATTI, 2005).

SILVA SIMÕES; COSTA (2003) utilizou uma RNA para classificar laranjas baseado em características de cor para o treinamento da rede. Utilizando 120 imagens de laranjas distintas, divididas em 5 classes, o sistema buscou identificar manchas ocorridas em frutos danificados, onde os resultados obtidos foram de 92% para identificar cores de laranjas entre amarelo, laranja claro e laranja escuro, e 81% para identificar mancha nos frutos.

Outra abordagem utilizando RNA para classificação, é o sistema implementado por CHTIOUI et al. (1996), onde o objetivo foi classificar 4 variedades de sementes, (sementes inteiras de rumex, aveia selvagem, luzerna e ervilhaça), num total de 120 imagens. Duas abordagens de reconhecimento de padrões foram testadas na classificação: análise discriminante, e redes neurais artificiais. Onde RNA obteve sucesso em comparação a análise discriminante. Com uma rede neural utilizando três camadas o sistema apresentou performance superior a 99% no conjunto de aprendizagem e no conjunto de testes. Combinações de características também melhoram os resultados, passando de 92% com características de forma e tamanho para 99% de acerto, combinando características de textura, forma e tamanho.

Redes neurais artificiais (RNA) é um modelo computacional inspirado na estrutura neural de organismos inteligentes, e que adquirem conhecimento através de experiência. Redes neurais artificiais (RNA) tem como característica resolver problemas em condições onde é difícil desenvolver modelos explícitos. Uma RNA consiste basicamente num modelo computacional em camadas de neurônios processadores, interligados por conexões ponderadas (pesos). Cada neurônio aplica uma função de ativação ao somatório de suas entradas com um polarizador. Neste trabalho foi utilizado uma RNA alimentada adiante (feed forward network), onde os



dados fluem das unidades de entrada para as unidades de saída, sem realimentação. O algoritmo de aprendizagem é o de retropropagação que consiste basicamente, no seguinte: dado um conjunto de pesos e polarizadores, a rede neural recebe o vetor de entrada, onde cada vetor representa as características da imagem. Durante o treinamento os pesos são ajustados para que a RNA mostre o resultado correto através da regra delta, representada pela equação 2.23:

$$f(v) = \frac{1}{1 + e^{-av}} a > 0 \quad (2.23)$$

Para o teste da rede é fornecido um vetor de características que não foi treinado, desse modo vetores que não foram treinados, mas que pertencem a mesma classe serão interpolados entre os vetores que a rede conhece e classificados como tais.

### 3 Método proposto

A abordagem proposta para a classificação de tipos de sementes é composta inicialmente pela criação de um conjunto de dados. O conjunto de dados criado foi adquirido das safras de 2013 e de 2014. Desta forma foi possível treinar e testar o sistema com sementes de safras diferentes, verificando a robustez do método. O sistema de classificação é composto também pela extração de características das imagens. Os descritores de características descritos no capítulo anterior foram utilizados (Haralick, LBP, CLBP, LPQ, LCP e Histograma). Várias combinações entre características destes descritores e alterações em seus parâmetros, foram realizados com o objetivo de encontrar o melhor resultado de classificação. O sistema proposto também contempla a criação de sub-imagens, geradas a partir das imagens originais dos conjuntos de dados. Variações do tamanho das sub-imagens foram realizadas também com o objetivo de encontrar o melhor resultado. Por fim foram testados dois modelos de classificadores, SVM e RNA, onde variações de suas características foram realizadas.

A proposta do método está ilustrado na Figura 3.1. Dada uma imagem de uma espécie de semente o processo inicializa definindo uma região central, aqui chamada de região de interesse.

Essa região exclui as bordas da imagem onde o fundo do recipiente aparece, eliminando assim interferências geradas por ele. A imagem foi adquirida originalmente colorida e nesta etapa foi feita a conversão para tons de cinza. A próxima etapa foi extrair as sub-imagens da região de interesse e extrair as características de cada uma delas formando assim o vetor de características. Um SVM hierárquico classifica a imagem dentro de um dos 13 tipos de sementes (classes).

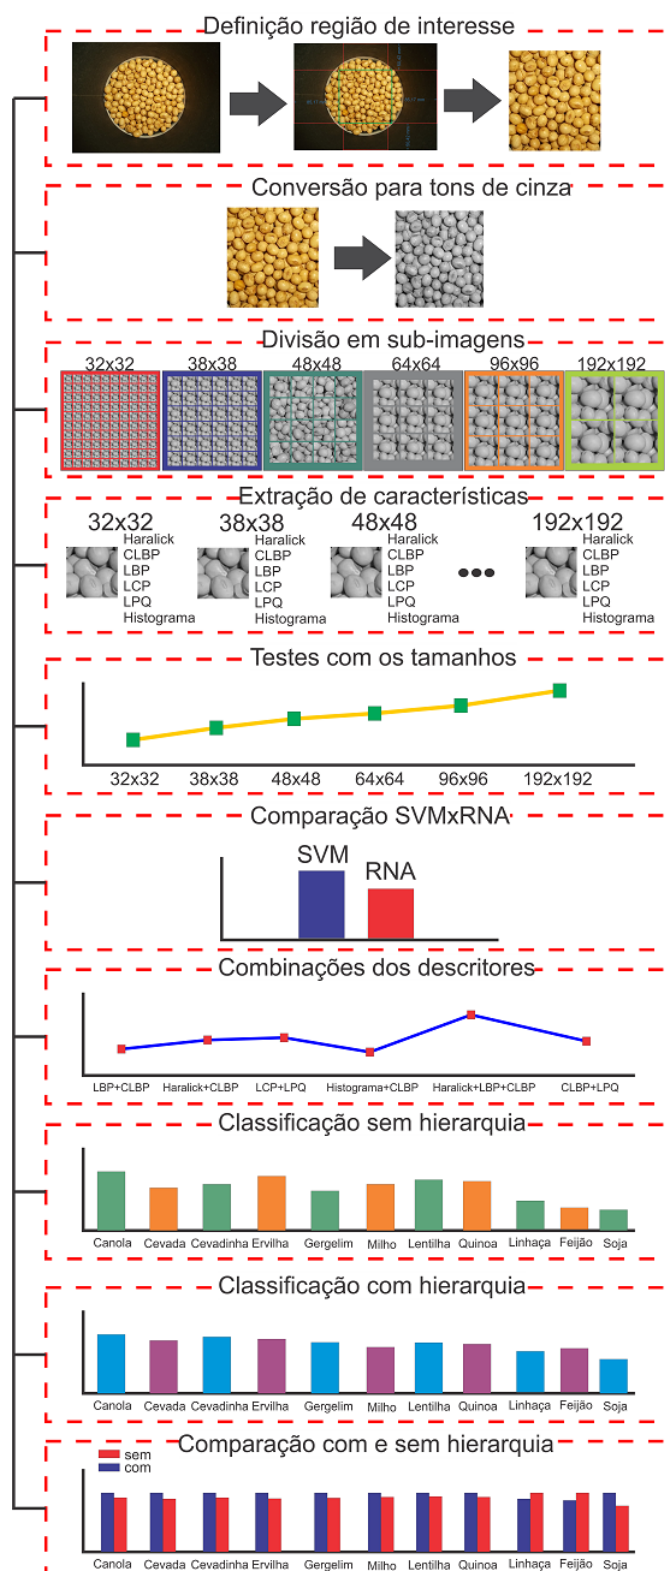


Figura 3.1: Método proposto para classificação de sementes.

Fonte (O Autor, 2015)

A figura 3.2 mostra a sequência hierárquica utilizada. Ao final do processo o resultado é estimado percentualmente de acordo com o número de sub-imagens classificadas na classe vencedora.

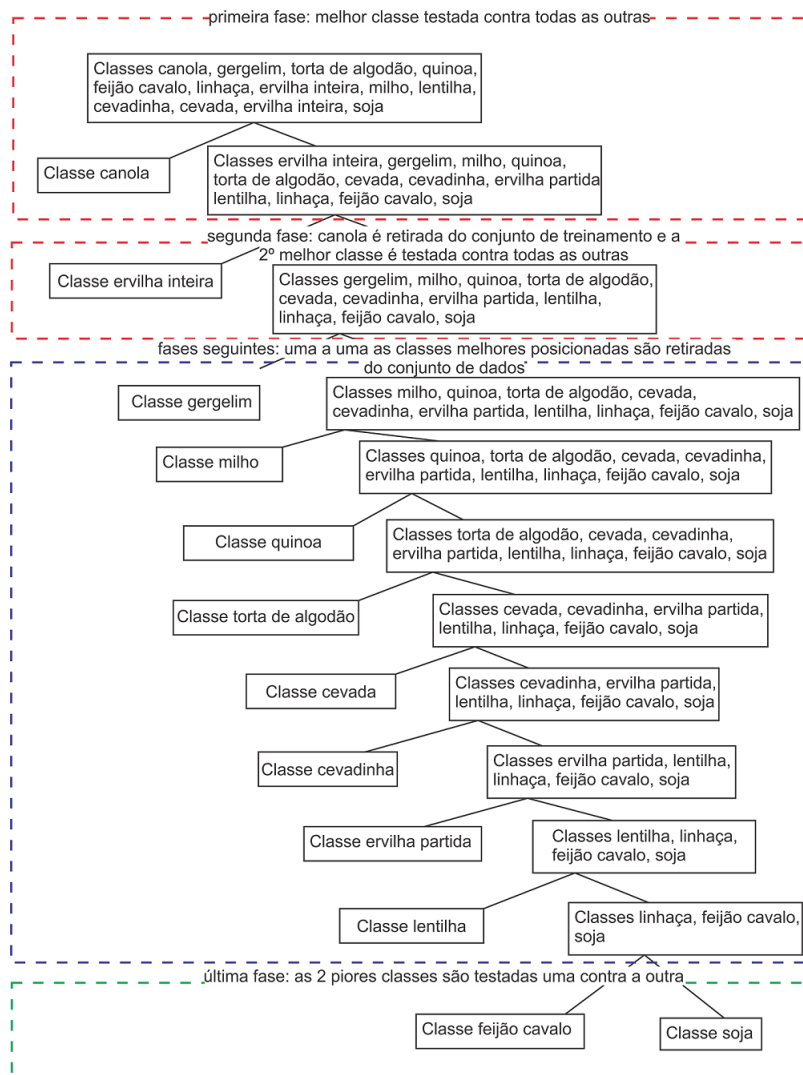


Figura 3.2: Modelo de hierarquia utilizado.

Fonte (O Autor, 2015)

### 3.1 Base de dados

Por não existir uma base de dados pública compatível com o objetivo do projeto, foi necessário criar uma base própria. Nesta parte inicial do trabalho foram tomados alguns cuidados na aquisição para garantir imagens com um mesmo padrão, dessa forma não alterando a extração de características das imagens. A Figura 3.3 mostra o aparato que foi utilizado para a aquisição das imagens das sementes. O método consiste em fazer uma foto numa resolução definida, com sementes a uma altura pré-determinada, para que as sementes fiquem sempre na mesma distância em relação a lente da câmera em todas as fotos, garantindo assim uma padronização nas imagens utilizadas na base de imagens. Na Figura 3.3 é possível ver o copo, a câmera fotográfica, um dispositivo que é encaixado no copo e que tem um encaixe preciso para a câmera.




Figura 3.3: (a) Copo para colocar sementes, (b) dispositivo fixador da câmera e (c) câmera fotográfica.

Fonte (O Autor, 2015)

Foi necessário desenvolver um fixador para a câmera, para que a mesma não sofresse alterações entre uma imagem e outra. Esse fixador foi projetado em uma impressora 3D de acordo com as dimensões da câmera fotográfica utilizada (modelo SAMSUNG T-65). A Figura 3.4 mostra esse dispositivo em detalhes.




Figura 3.4: Dispositivo fixador da câmera fotográfica.

Fonte (O Autor, 2015)

A Figura 3.5 ilustra o método que foi utilizado para manter a altura constante. O copo onde as sementes são colocadas tem uma marcação indicando o limite para que seja despejada amostras de sementes até aquele ponto.

Outro cuidado tomado foi com a cor da parede do recipiente onde as amostras foram alocadas. Dependendo da cor, o reflexo das imagens era alterado, interferindo na qualidade das imagens. Testes com diferentes materiais foram feitos para encontrar o melhor resultado. Na Figura 3.6 é mostrado o recipiente sem e com o revestimento. Na Figura 3.6 a) é possível visualizar o ambiente ao redor onde o copo está colocado, esse ambiente tem variações de luminosidade o que altera o resultado da imagem obtida, interferências por meio de luz ou sombra podem ocorrer. Na Figura 3.6 b) o problema de luminosidade é resolvido com o revestimento do copo.




Figura 3.5: Ilustração do dispositivo.

Fonte (O Autor, 2015)




Figura 3.6: Em a) é mostrada uma imagem sem o revestimento e em b) a mesma amostra no copo com o revestimento.

Fonte (O Autor, 2015)

Um filtro para o flash da câmera foi necessário, pois a luz gerada por ele afetava as imagens, deixando-as com brilho excessivo. Esse filtro foi desenvolvido com uma película plástica colada sobre o flash da câmera, dessa maneira atenuando o efeito da luz sobre as imagens. A melhor combinação foi obtida com fita dupla face 3M, o aparato completo pode ser visto na Figura 3.7.




Figura 3.7: (a) - Detalhe da membrana (b) Copo revestido (c) Visão geral do aparato.

Fonte (O Autor, 2015)

Na Figura 3.8 é mostrado a diferença entre as imagens com a utilização da película e do revestimento interno do copo.




Figura 3.8: Exemplo de imagens com a utilização de película e revestimento do copo.

Fonte (O Autor, 2015)



Dessa forma as fotos foram padronizadas, na resolução de 1 Mega *pixel* (1024x768). Exemplos de imagens obtidas com o sistema são mostrados na Figura 3.9. O conjunto de dados obtido foi separado em 2 partes, Safra 2013 e Safra 2014. Cada safra contém 13 classes diferentes, que são divididas pelo tipo de sementes e são mostradas na Tabela 3.1. Na safra de 2013 foram adquiridas 10 imagens de cada tipo de semente, totalizando 130 imagens. Na safra de 2014 foram obtidas 15 imagens de cada tipo, exceto cevada que foram obtidas 30 imagens e torta de algodão que foram obtidas 14 imagens, totalizando 209 imagens. Visto que o número de imagens foi pequena para safra de 2013, um número maior de imagens da safra de 2014 foi obtida. A classe *Cevada* foi obtida 2 vezes durante o processo de aquisição ficando assim com 30 imagens, e a classe *Torta de algodão* teve uma das imagens corrompidas, ficando assim com 14 imagens.

Tabela 3.1: Descrição dos tipos de sementes e suas correspondentes quantidades.

Tipo	Safra 2013 Qtde.	Safra 2014 Qtde.
CANOLA	10	15
CEVADA	10	30
CEVADINHA	10	15
ERVILHA INTEIRA	10	15
ERVILHA PARTIDA	10	15
FEIJÃO CAVALO	10	15
GERGELIM	10	15
LENTILHA	10	15
LINHAÇA	10	15
MILHO	10	15
QUINOA	10	15
SOJA	10	15
TORTA DE ALGODÃO	10	14




Figura 3.9: Exemplo de imagens obtidas. Em a) Canola, b) Cevada, c) Cevadinha, d) Ervilha Partida, e) Feijão Cavalo, f) Gergelim, g) Linhaça, h) Milho, i) Quinoa, j) Ervilha Inteira, k) Lentilha, l) Soja, m) Torta de Algodão.

Fonte (O Autor, 2015)

### 3.2 Criação de Blocos de Imagens

Para aumentar nosso conjunto de dados e poder processar mais rápido as imagens durante as etapas de extração de características e classificação das semen-

tes, as imagens foram divididas em sub-imagens. Dessa maneira a imagem obtida originalmente é dividida em blocos de tamanhos idênticos. Outra motivação para dividir as imagens em partes menores, foi o fato de que imagens menores tendem a ser mais homogêneas, isso devido ao assentamento variado das imagens dentro do copo do equipamento. O tamanho de bloco ideal foi objeto de estudo e está descrito nos resultados. Os tamanhos testados foram 32x32, 38x38, 48x48, 64x64, 96x96 e 192x192 *pixels*.

As sub-imagens foram obtidas da parte interna da imagem original, descartando as bordas onde aparece a cor do revestimento do copo. No centro da imagem foi definido um retângulo, que indica a área útil para o recorte das imagens. A Figura 3.10 mostra um exemplo do modelo utilizado. Este procedimento foi realizado em todas as imagens obtidas e dependendo do tamanho do bloco a quantidade de sub-imagens varia.




Figura 3.10: Representação do modelo que fragmentação das imagens.

Fonte (O Autor, 2015)

### 3.2.1 Tamanho das sub-imagens

Em análise de textura em reconhecimento de padrões é comum extrair informações da textura utilizando sub-imagens recortadas da imagem original (ORLANDO, 2003). Em algumas variedades de sementes, sub-imagens muito pequenas podem não representar todas as informações necessárias para ser discriminante durante o processo de extração de características. Por outro lado, sub-imagens muito grandes podem generalizar muito algumas informações de textura e também apresentar resultados ruins durante a classificação.

Em alguns trabalhos relacionados ao reconhecimento de plantas e madeira florestal, diversos tamanhos de sub-imagens foram utilizados. SHEARER; HOLMES et al. (1990), BURKS et al. (2000) e PARK; CHEN (2001) utilizaram sub-imagens de 64x64 *pixels*, já YANG et al. (2000), utilizou tamanho de 100x100 *pixels* e FILHO et al. (2014) conseguiu melhores resultados utilizando imagens de 652x489 e 544x408. Esta grande variação mostra que a escolha do tamanho das sub-imagens depende da aplicação que está sendo estudada.

O tamanho das sub-imagens pode influenciar diretamente no resultado da classificação. TANG et al. (1999) notaram que o tempo de processamento e a classificação foram influenciados pelo tamanho das sub-imagens. Dentre os tamanhos testados: 9x9, 13x13 e 17x17 *pixels*, o de maior tamanho apresentou melhores resultados, semelhante ao resultado obtido por ORLANDO (2003) que testou 17x17, 34x34 e 64x64 *pixels*. FILHO et al. (2014) porém obteve melhores resultados em tamanhos intermediários, em seu trabalho foram testados os seguintes tamanhos: 1632x1224, 1088x816, 652x489, 544x408, 466x349, 408x306 e 326x244. Onde o melhor resultado foi obtido nas sub-imagens de tamanho 652x489.

Neste trabalho inicialmente foi dividido a região de interesse que tem 384x384

*pixels*, em blocos de  $38 \times 38$  *pixels*, gerando uma matriz de sub-imagens de  $10 \times 10$ , totalizando 100 sub-imagens. Posteriormente visando melhorar os resultados obtidos, testamos sub-imagens de  $32 \times 32$  e  $64 \times 64$  *pixels*, gerando respectivamente 144 e 36 sub-imagens de cada imagem original. Novamente buscando melhores resultados, dividimos a região de interesse em 4 partes (sub-imagens  $192 \times 192$  *pixels*), em 16 partes (sub-imagens  $96 \times 96$  *pixels*) e em 64 partes (sub-imagens  $48 \times 48$  *pixels*). Nas Figuras 3.11 e 3.12 é mostrado um exemplo das sub-imagens obtidas de Canola e Soja respectivamente.




Figura 3.11: Representação do modelo que fragmentação das imagens da espécie *Canola*.

Fonte (O Autor, 2015)




Figura 3.12: Representação do modelo que fragmentação das imagens da espécie *Soja*.

Fonte (O Autor, 2015)

### 3.2.2 Extração das sub-imagens

Conforme descrito no item 3.2 deste trabalho, as sub-imagens foram retiradas da parte central da imagem original. Foi selecionado uma região retangular na imagem, chamada de região de interesse de tamanho  $384 \times 384$  *pixels*. A figura 3.13 mostra os limites utilizados para a seleção da região de interesse.




Figura 3.13: Limites utilizados na região de interesse para extração das sub-imagens.

Fonte (O Autor, 2015)

A região selecionada exclui as bordas, pois elas contém o revestimento utilizado no copo que evita a incidência de luz externa. Esse revestimento tem influência direta na extração de características das imagens, já que o mesmo não faz parte da amostra e pode sofrer variações de acordo com o tipo de semente.

A região delimitada tem  $384 \times 384$  *pixels*, depois de delimitada a região de interesse da imagem, um algoritmo desenvolvido, recortou  $N$ -Sub-imagens dessa região, onde  $N$  é o número gerado de sub-imagens, que depende diretamente do tamanho selecionado. O procedimento para o recorte segue o algoritmo que ocorre na

seguinte ordem: (i) inicia-se no canto superior esquerdo, descendo até o canto inferior esquerdo, até o limite marcado; (ii) depois é deslocado a largura da sub-imagem para o lado direito, então novamente na parte superior da imagem desce até o limite inferior; (iii) esse procedimento é realizado até chegar no limite inferior direito da imagem.

O número total de imagens depende do tamanho das sub-imagens, o retângulo central tem 384x384 *pixels*, neste caso se as sub-imagens tiverem tamanho de 192x192 *pixels*, o número total de sub-imagens será 4. Esse procedimento foi aplicado a todas as imagens do conjunto de dados, a tabela 3.2 mostra os tamanhos e as quantidades que foram utilizados neste trabalho.

Tabela 3.2: Tamanhos e quantidades de sub-imagens geradas.

Tamanho da sub-imagem	Quantidade safra 2013	Quantidade safra 2014
32x32	18720	27936
38x38	13000	20900
48x48	8320	13376
64x64	4680	7524
96x96	2080	3344
192x192	520	836

### 3.3 Treinamento SVM

O modelo de treinamento para o SVM utilizado neste trabalho foi o método um-contratodos, onde as classes eram organizadas em duas, uma contendo a classe objetivo, e a outra classe contendo todas as outras sementes. Análises individuais dos descritores foram realizadas, testes com tipos diferentes de *kernels* também foram alvo de análise, assim como o tamanho das sub-imagens. O treinamento dos SVMs foi feito com as imagens da safra de 2013 e os teste dos SVMs com as imagens da safra de 2014, evitando assim uma tendência do classificador em utilizar imagens da

mesma safra para treino e teste.

### 3.3.1 *Kernel*

Os *kernels* utilizados neste trabalho são os fornecidos por padrão na função *svmtrain* do software MATLAB 2012b. São eles:

- LINEAR Linear kernel.
- QUADRATIC Quadratic kernel.
- POLYNOMIAL Polynomial kernel.
- RBF Gaussian Radial Basis Function.
- MLP Multilayer Perceptron kernel.

Os cinco modelos de *kernels* foram testados para cada tamanho de sub-imagens. Esse parâmetro foi importante na realização dos testes de treinamento dos SVMs. A variação do tipo de *kernel* mostrou ser dependente ao tamanho do vetor de características utilizados, para vetores com muitas características, como por exemplo, combinações de descritores, os *kernels Quadratic* e *Polynomial* tiveram desempenho melhor. Já para vetores com poucas características, como por exemplo, Haralick o *kernel Linear* obteve melhor resultado.

O *kernel* que obteve melhor resultado nos descritores testados, foi o QUADRATIC, representado pela equação 3.1:



$$\begin{aligned}
k(x, z) &= (x'z)^2 \\
&= z'(xx')z \\
&= \text{vec}(zz'), \text{vec}(xx')
\end{aligned} \tag{3.1}$$

onde  $\text{vec}(A)$  empilha as colunas da matriz  $A$  em cima uns dos outros. Assim,  $K$  corresponde ao mapa de características:

$$\phi : x \mapsto \text{vec}(xx') \tag{3.2}$$

### 3.3.2 Combinação de descritores

Os primeiros testes utilizaram os descritores individualmente e, em seguida, foram testadas combinações. O principal critério para combinação de descritores foi seu desempenho individual. No total foram utilizados 6 tipos de descritores, que utilizam análises estatísticas, estruturais, espectrais e de níveis de cinza. As combinações foram testadas nos 6 tamanhos de sub-imagens (32x32, 38x38, 48x48, 64x64, 96x96 e 192x192) e nos 5 tipos de *kernels*. As combinações realizadas são mostradas na Tabela 3.3. O método utilizado para avaliação dos resultados foram a média da taxa de acerto e o desvio padrão.

## 3.4 Hierarquia

### 3.4.1 Treinamento

A partir dos resultados obtidos com SVMs treinados utilizando o método um-contra-todos, foi possível ordenar quais classes obtiveram melhores resultados.

Tabela 3.3: Combinações realizadas com diferentes tipos de descritores.

ID	Descritores
1	LBP+HARALICK
2	LBP+LPQ
3	LBP+LPQ+HARALICK
4	CLBP+LBP
5	CLBP+LBP+LPQ
6	CLBP+LBP+HARALICK
7	CLBP+LBP+LPQ+HARALICK
8	LBP+LCP
9	CLBP+LPQ
10	LBP+LCP+HARALICK
11	CLBP+HARALICK
12	LBP+LCP+LPQ+HARALICK
13	LPQ+HARALICK
14	CLBP+LPQ+HARALICK
15	LBP+LCP+LPQ
16	CLBP+LBP+LCP+HARALICK
17	CLBP+LBP+LCP
18	CLBP+LBP+LCP+LPQ
19	CLBP+LBP+LCP+LPQ+HARALICK
20	CLBP+LCP
21	LCP+HARALICK
22	CLBP+LCP+HARALICK
23	CLBP+LCP+LPQ
24	CLBP+LCP+LPQ+HARALICK
25	LCP+LPQ
26	LCP+LPQ+HARALICK

O processo de hierarquia proposto neste trabalho consiste basicamente em treinar um SVM com a classe que obteve melhor resultado no método um-contra-todos e testá-lo contra todas as outras, ao fim do teste foi contabilizado quantas imagens foram classificadas nesta classe, passando então para o próximo SVM, que foi treinado com a segunda melhor classe, e testado com todas as outras menos a primeira, que foi utilizado no passo anterior.

Esse processo se repete até as últimas duas classes, que por definição são as piores classificadas. No final do processo foi contabilizado quantas imagens foram classificadas em cada classe, a classe com maior número de imagens classificadas é escolhida como resultado. A Figura 3.14 ilustra o modelo proposto. A motivação para utilizar esse método é que a melhor classe tende a ter menor margem de erros quando treinada com todas as outras, assim a imagem de entrada no primeiro passo do método tem maior certeza da classificação, deixando as piores classes serem treinadas com menor número de classes, diminuindo assim a confusão do classificador quando a imagem de entrada pertence a uma classe com desempenho ruim.

### 3.4.2 Classificação

A Figura 3.14 representa o processo de classificação realizado no método proposto, onde consiste em uma imagem de entrada ser dividida de acordo com o tamanho da sub-imagem desejada, então um SVM é treinado com todas as 13 classes. O resultado da classificação do SVM 1 é contabilizado, e caso haja imagens que não foram classificadas neste SVM, essas imagens então são passadas para classificação do segundo SVM que foi treinado com todas as classes menos a primeira, e novamente caso exista alguma imagem não classificada, essa(s) imagem(ns) são passadas para o próximo SVM. Esse processo é repetido até chegar nas duas últimas classes. Caso todas as imagens sejam classificadas antes do fim do processo o mesmo é interrompido e o resultado contabilizado. No caso do exemplo da Figura 3.14 o resultado seria o mostrado na Tabela 3.4.

O resultado seria contabilizado percentualmente para cada classe, e a classe com maior valor seria considerada a saída do sistema. No caso do exemplo a classe classificada seria a 1 com 86,11%.

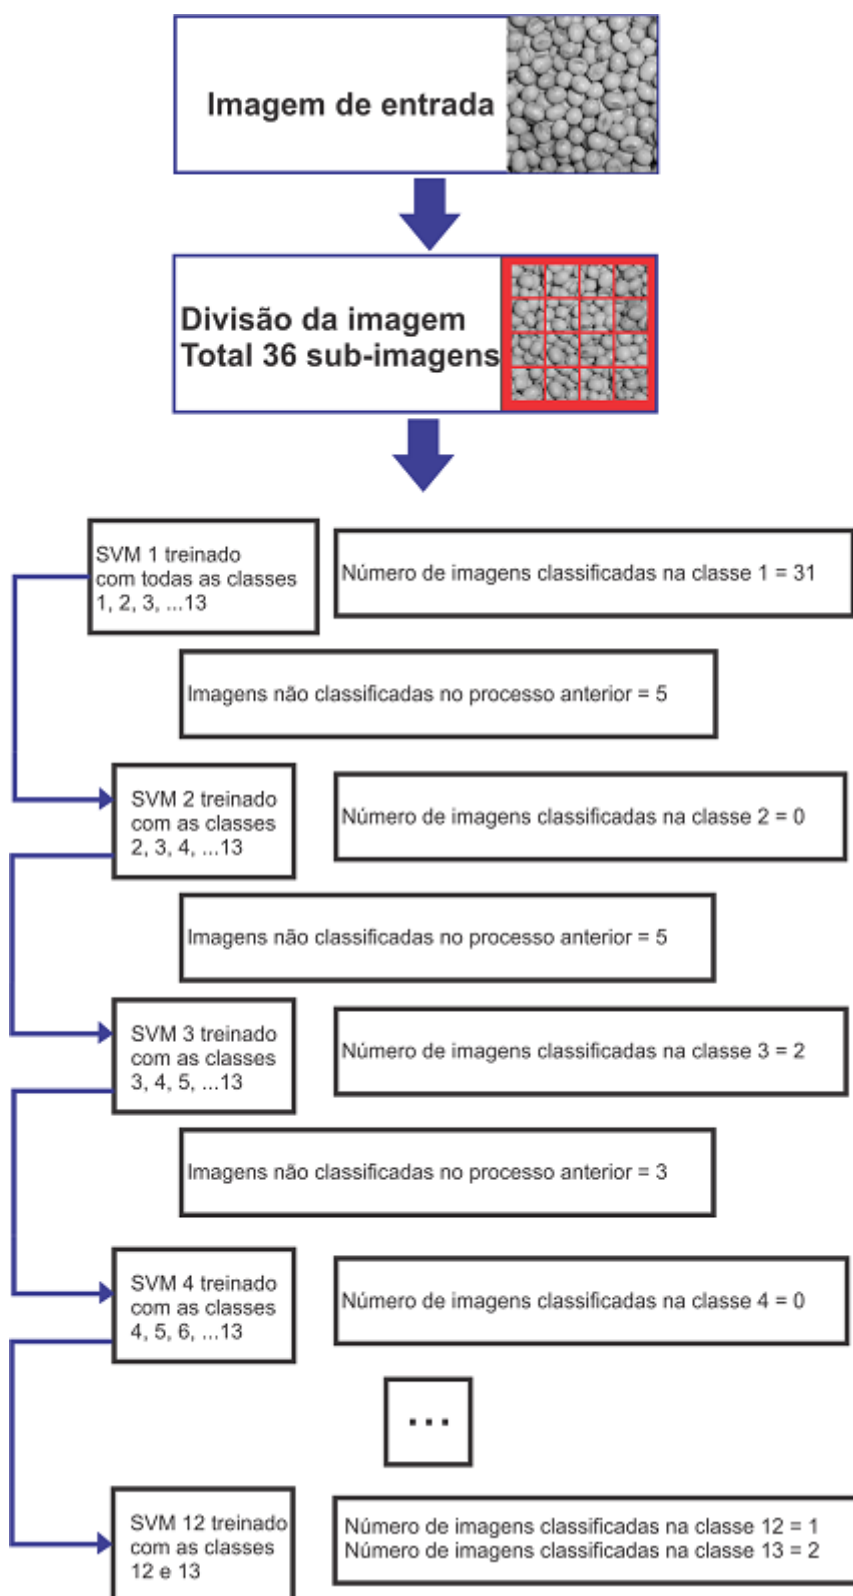


Figura 3.14: Descrição do método proposto.

Fonte (O Autor, 2015)

Tabela 3.4: Descrição do processo de hierarquia.

SVM treinado	Núm. img. de entrada	Núm. img. classificada	Acerto
13 classes	36	31	86,11%
12 classes	5	0	0,0%
11 classes	5	2	5,55%
10 classes	3	0	0,0%
...			
2 classes	3	1	2,77%
2 classes	2	2	5,55%

## 4 Resultados e Discussão

Este capítulo está dividido em 5 partes. A primeira parte descreve a métrica de avaliação utilizada. Para avaliar os resultados obtidos foi utilizado o percentual de acerto e o número de erros na saída do classificador. Para avaliação geral de cada descritor foi calculado a média e o desvio padrão dos resultados de cada classe. Na segunda seção, diferentes tamanhos das sub-imagens foram testados, com o intuito de avaliar o impacto do resultado na classificação. No total foram testados 6 tamanhos diferentes de sub-imagens (*vide* seção 3.2.1). A terceira seção descreve a extração e análise de características, nesta etapa são avaliados os modelos de descritores que foram utilizados no treinamento dos classificadores. Com base nos experimentos realizados anteriormente, a quarta parte dos experimentos foi a definição de um classificador. Os modelos testados foram SVM e RNA. A avaliação foi feita comparando a média e o desvio padrão dos resultados obtidos entre os dois classificadores. Na quinta seção são apresentados os resultados com o método de SVM hierárquico.

### 4.1 Métrica de avaliação

Para os testes realizados, a métrica de avaliação adotada foi a porcentagem de acerto obtida pela classe com mais amostras classificadas. Dessa maneira a classe vencedora tem um valor percentual da quantidade de amostras submetidas ao modelo em teste. Por exemplo para 100 imagens de entrada, a classe vencedora foi *Canola* e identificou 85 das 100 imagens, neste caso o método considerou que 85% das imagens avaliadas pertencem a classe de *Canola*. Na saída do classificador a classe vencedora é comparada com a classe esperada, caso a saída seja diferente da

classe esperada é contabilizado um erro, e percentual de acerto é considerado 0%. Após testar todas as imagens de todas as classes, é calculada a média do percentual de acerto de cada classe, e o desvio padrão, esses dados são utilizados como métrica de avaliação.

## 4.2 Definição do tipo de classificador

A definição do tipo de classificador foi feita analisando o desempenho obtido com cada algoritmo. Para os testes entre os classificadores foram utilizadas sub-imagens de 192x192 *pixels*, das 13 classes analisadas neste trabalho. Foram analisados 2 tipos de classificadores, SVM e RNA. Cada um dos classificadores teve seus parâmetros ajustados para obter a melhor resposta, e com as duas melhores configurações foram comparados entre si. Foi utilizado como descritor para o teste a combinação LBP e Haralick. A Figura 4.1 mostra o desempenho dos dois classificadores analisados.




Figura 4.1: Desempenho dos classificadores RNA e SVM.

Conforme mostrado na Figura 4.1 o desempenho dos classificadores é muito parecido, com exceção das classes *Cevadinha* e *Soja*, onde *Cevadinha* tem desempenho bem inferior no classificador RNA, quando comparado com o classificador SVM. Em ambos os classificadores a *Soja* tem os piores resultados, porém com SVM a taxa de acerto foi de 61,7% contra 17,5% na RNA. Devido a essas diferenças foi escolhido o classificador SVM como padrão para os testes.

### 4.3 Dimensão das sub-imagens

Um fator importante para um bom desempenho do classificador, é a escolha do tamanho das sub-imagens, utilizadas pra extração de características. Com o intuito de verificar qual a influência que o tamanho das imagens tem nas amostras, seis tamanhos diferentes de sub-imagens foram testados (32x32, 38x38, 48x48, 64x64, 96x96 e 192x192 *pixels*). Para este teste preliminar foi utilizado a média de acertos dos descritores (CLBP, LBP e LCP) que apresentaram os melhores resultados. A Figura 4.2 mostra um gráfico comparativo entre os tamanhos testados, utilizando a média dos resultados e o desvio padrão. É possível observar que a medida que o tamanho da imagem aumenta a média de acertos cresce e o desvio padrão diminui, mostrando que quanto maior a imagem mais o sistema acerta. Isso demonstra que o tamanho tem grande influência no resultado.

Para a escolha do tamanho ideal das sub-imagens, foi analisado o desempenho das duas melhores classificadas. A Figura 4.3 mostra o desempenho para cada classe nos dois melhores tamanhos classificados (96x96 e 192x192 *pixels*) avaliando a porcentagem de acerto obtida.

Como mostrado no gráfico da Figura 4.3 os resultados para cada classe é muito parecido, tendo como pior resultado a soja. O critério utilizado para escolha






Figura 4.2: Comparação da média e desvio padrão entre todos os tamanhos testados: 32x32, 37x37, 48x48, 64x64, 96x96 e 192x192.



Figura 4.3: Resultado da classificação para cada classe nos tamanhos 96x96 e 192x192.

do tamanho ideal de sub-imagem, foi o resultado da média da classificação e o desvio padrão, o tamanho 96x96 obteve média de classificação de 88,04% e desvio padrão

de 18,62%, já o tamanho de 192x192 obteve resultado de média de classificação de 94,49% e desvio padrão de 10,53%. Valores que evidenciam que o melhor tamanho a ser utilizado é o de 192x192 *pixels*. Mesmo gerando uma quantidade menor de sub-imagens (40 para cada imagem original, contra 160 no tamanho 96x96), o ganho na taxa de acerto e no desvio padrão é significativo. Todos os testes descritos nas próximas seções utilizaram as sub-imagens de 192x192, somente quando isso não ocorreu o tamanho utilizado é citado.

## 4.4 Extração e análise das características

Extração e análise das características tem papel fundamental na correta classificação de sementes, pois nela está a base de conhecimento dos classificadores. Com o intuito de avaliar o impacto nos resultados, testes foram realizados com 6 tipos de descritores de características (*vide* seção 2.2). A avaliação foi feita com base nos resultados obtidos na classificação. Os modelos testados neste trabalho foram alguns dos mais utilizados na literatura, abordando análises estatísticas, estruturais e espectrais. A variação no formato, tamanho e textura das sementes, bem como, o seu posicionamento dentro do copo, dificultam a escolha de um modelo de descritor específico. Testes individuais foram realizados para avaliar o desempenho de cada tipo de descritor, assim foi possível avaliar sua contribuição em diferentes tipos de sementes. Experimentos foram realizados combinando tipos de descritores, com o objetivo de melhorar os resultados de classificação.

### 4.4.1 Haralick

Nos experimentos utilizando o método de Haralick os descritores foram obtidos utilizando os ângulos ( $\Theta = 0, 45, 90$  e  $135$ ) e distância ( $d = 1$ ). Essa configu-

ração foi a que obteve melhores resultados. O descritor resulta num vetor com 13 características.

As características foram extraídas das sub-imagens definidas na seção anterior e o vetor resultante então foi utilizado no treinamento do classificador SVM, com o *kernel* RBF que obteve melhor resultado para este método. Exemplos dos histogramas extraídos dos descritores de Haralick podem ser observados na Figura 4.4. A escolha das sementes de *Canola*, *Soja* e *Feijão Cavalo* para representar os histogramas, ocorreu devido ao fato de serem sementes bem diferentes entre si, deixando mais relevantes as características obtidas.




Figura 4.4: Resultados do histograma dos descritores de Haralick aplicados as sub-imagens de Canola, Soja e Feijão Cavalo.

É possível perceber nos histogramas gerados que o sétimo descritor (soma da variância) é o que apresentou maior variação, mostrando ser a característica mais discriminante.

Utilizando as informações geradas pelos descritores de Haralick foi treinado um SVM, que utilizou imagens da safra de 2013 e validado com informações obtidas das imagens da safra de 2014. Os resultados são mostrados na Tabela 4.1.

Tabela 4.1: Resultados obtidos usando descritores de Haralick com SVM *kernel* RBF.

Classe esperada	Classe resultante	Acerto %
Canola	Canola	93,33
Cevada	Cevadinha	0,00
Cevadinha	Cevadinha	98,33
Ervilha Inteira	Ervilha Inteira	100,00
Ervilha Partida	Ervilha Partida	100,00
Feijão Cavalo	Feijão Cavalo	86,67
Gergelim	Gergelim	100,00
Lentilha	Lentilha	100,00
Linhaça	Linhaça	90,00
Milho	Milho	100,00
Quinoa	Quinoa	100,00
Soja	Soja	1,67
Torta de Algodão	Torta de Algodão	94,64
	Média	81,90
	Desvio padrão	36,24
	Erro	1

Na análise individual dos descritores de Haralick, é possível notar de acordo com os resultados da Tabela 4.1 que duas classes tem resultados ruins, e uma delas (*Cevada*) é classificada errada e a outra (*Soja*) tem taxa de acerto de apenas 1,67%. Os resultados ruins demonstram que o classificador utilizando o método de Haralick tem dificuldade na discriminação destas classes.

#### 4.4.2 LBP

Nos experimentos utilizando a técnica LBP os códigos foram extraídos utilizando uma matriz de 3x3 com raio  $R = 1$ . Isso caracteriza computar o valor do pixel central a partir dos 8 vizinhos mais próximos num raio de 1, conforme ilustrado na Figura 4.5. Essa configuração obteve melhores resultados em nossos experimentos.




Figura 4.5: Representação do LBP para uma matriz 3x3 com raio 1.

Da mesma forma que os descritores de Haralick, os códigos LBP foram extraídos de sub-imagens, resultando num vetor de 59 características que foi utilizado para treinar um classificador SVM. Os histogramas dos códigos LBP são mostrados na Figura 4.6.

O treinamento do classificador SVM com os códigos LBP teve como melhor resultado o *kernel* com a função QUADRATIC. Os valores obtidos estão representados na Tabela 4.2.

Ao contrário do método de Haralick, o LBP não confundiu nenhuma classe, ficando apenas com *Soja* e *Feijão Cavalo* abaixo dos 80% de acerto. Utilizando o descritor LBP, a classe *Feijão Cavalo* apresentou resultado bastante inferior em comparação com o método anterior. A comparação entre os métodos é mostrado na Figura 4.7.

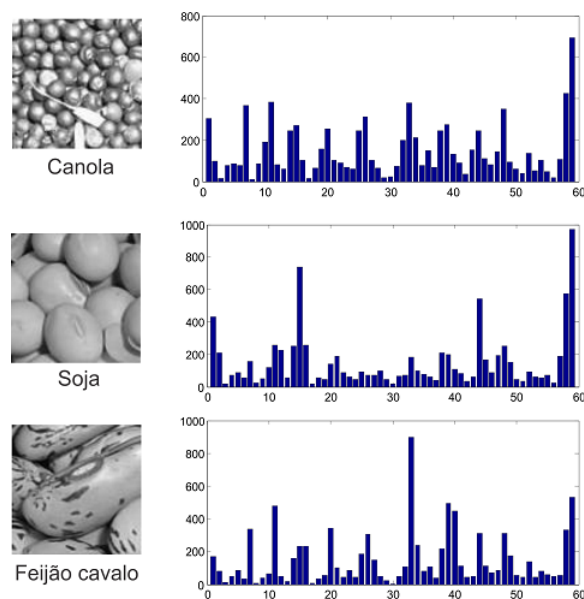


Figura 4.6: Um exemplo do Histograma dos códigos LBP em imagens de canola, soja e feijão cavalo.




Figura 4.7: Comparação entre os descritores de Haralick e LBP.

É possível notar na Figura 4.7 que o desempenho de cada classe varia dependendo do descritor, isso indica que determinado método é mais discriminante para algumas variedades, e que combinações podem ter bom resultados.

Tabela 4.2: Resultados obtidos utilizando os códigos LBP com SVM *kernel* QUADRATIC.

Classe esperada	Classe resultante	Acerto %
Canola	Canola	100,00
Cevada	Cevada	96,67
Cevadinha	Cevadinha	70,00
Ervilha Inteira	Ervilha Inteira	91,67
Ervilha Partida	Ervilha Partida	98,33
Feijão Cavalo	Feijão Cavalo	78,33
Gergelim	Gergelim	100,00
Lentilha	Lentilha	91,67
Linhaça	Linhaça	85,00
Milho	Milho	98,33
Quinoa	Quinoa	100,00
Soja	Soja	61,67
Torta de Algodão	Torta de Algodão	100,00
	Média	90,13
	Desvio padrão	12,76
	Erros	0

#### 4.4.3 CLBP

Da mesma forma como foram extraídos os códigos LBP, também foi utilizada uma matriz de 3x3 com raio igual a 1 no método CLBP. A técnica LBP computa o valor do pixel central em relação a seus vizinhos, já o CLBP contempla também valores de magnitude e intensidade do pixel. O vetor resultante tem 118 características e foi extraído das imagens da safra de 2013, esse vetor foi utilizado para treinar um classificador SVM, que foi validado com as imagens da safra de 2014. O classificador SVM teve seu melhor resultado com o *kernel* POLYNOMIAL. O histograma dos códigos CLBP são mostrados na Figura 4.8, onde é importante notar a semelhança dos resultados do histograma nas classes Soja e Feijão cavalo, isto reflete diretamente na classificação onde os resultados de ambos são os mais baixos, decorrente da semelhança dos códigos CLBP utilizados no classificador. Da mesma forma

como nos outros 2 experimentos anteriores, é possível perceber uma tendência na classe com o pior resultado, mostrando dificuldade do classificador para discriminar a classe *Soja*.




Figura 4.8: Histograma dos códigos CLBP em imagens de canola, soja e feijão cavalo.

Os resultados são apresentados na Tabela 4.3. Um comparativo entre os modelos LBP e CLBP é apresentado na Figura 4.9, que mostrou bastante semelhança entre as técnicas. Isso deve-se a implementação dos modelos serem baseados nos mesmos fundamentos, sendo o método CLBP uma variação do método LBP. Porém, é possível perceber que o CLBP tem resultados melhores que o LBP gerando uma média de acerto melhor em mais de 2 pontos percentuais e um desvio padrão muito parecido.



Tabela 4.3: Resultados obtidos utilizando os códigos CLBP com SVM *kernel* POLYNOMIAL.

Classe esperada	Classe resultante	Acerto %
Canola	Canola	100,00
Cevada	Cevada	94,17
Cevadinha	Cevadinha	96,67
Ervilha Inteira	Ervilha Inteira	100,00
Ervilha Partida	Ervilha Partida	91,67
Feijão Cavalo	Feijão Cavalo	86,67
Gergelim	Gergelim	100,00
Lentilha	Lentilha	93,33
Linhaça	Linhaça	93,33
Milho	Milho	98,33
Quinoa	Quinoa	100,00
Soja	Soja	53,33
Torta de Algodão	Torta de Algodão	100,00
	Média	92,88
	Desvio padrão	12,60
	Erros	0




Figura 4.9: Comparação entre os descritores de LBP e CLBP.

#### 4.4.4 LCP

A técnica LCP combina o método LBP com a extração de características microscópicas, é considerado um método robusto a ruídos na literatura. O método faz

um análise de frequência utilizando as informações microscópicas obtidas, tornando o modelo invariante a rotações, o que em nosso experimento foi bastante importante, pois as sementes eram alocadas de forma aleatória, tendo variações em todas os ângulos e rotações. O modelo LCP foi aplicado utilizando uma matriz de 3x3 com raio de 2. Essa configuração apresentou os melhores resultados para este método. O histograma das imagens de canola, soja e feijão cavalo são mostrados na Figura 4.10.

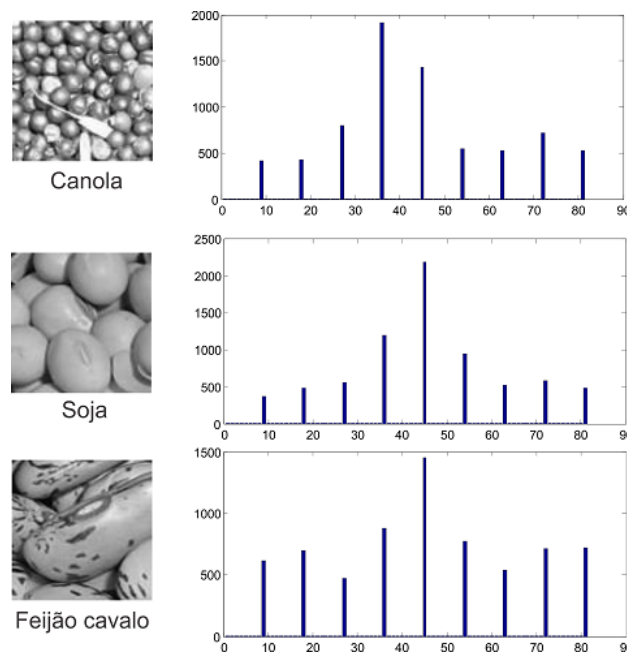


Figura 4.10: Exemplo de Histograma dos códigos LCP em imagens de canola, soja e feijão cavalo.

O vetor de saída do método LCP gerou 81 características, os vetores foram utilizados para treinar um classificador SVM com *kernel* QUADRATIC, os resultados obtidos são mostrados na Tabela 4.4.

Mais uma vez a classe *Soja* apresentou o pior resultado, mostrando até aqui ser a classe com maior dificuldade para o classificador. Um comparativo entre os métodos LBP, CLBP e LCP analisados até aqui são mostrado na Figura 4.11. Os

Tabela 4.4: Resultados obtidos utilizando os códigos LCP com SVM *kernel* QUADRATIC.

Classe esperada	Classe resultante	Acerto %
Canola	Canola	100,00
Cevada	Cevada	91,67
Cevadinha	Cevadinha	88,33
Ervilha Inteira	Ervilha Inteira	100,00
Ervilha Partida	Ervilha Partida	90,00
Feijão Cavalo	Feijão Cavalo	90,00
Gergelim	Gergelim	100,00
Lentilha	Lentilha	75,00
Linhaça	Linhaça	98,33
Milho	Milho	88,33
Quinoa	Quinoa	100,00
Soja	Soja	21,67
Torta de Algodão	Torta de Algodão	100,00
	Média	87,95
	Desvio padrão	21,25
	Erros	0

métodos apresentam bastante semelhança nos resultados, com pequenas variações em algumas classes. O método LCP apresentou uma pequena melhora na classe linhaça, e nas outras se manteve basicamente entre LBP e CLBP.




Figura 4.11: Comparação entre os descritores de LBP, CLBP e LCP.

#### 4.4.5 LPQ

Mesmo tendo adquirido imagens em um ambiente controlado, sem variação de luminosidade externa, com distância controlada e cuidados no ajuste do foco, algumas imagens saíram borradas e/ou fora de foco. Essas degradações tem impacto direto na extração de características. A técnica LPQ é bastante robusta a esse tipo de problema, e foi utilizada neste trabalho com o objetivo de minimizar defeitos na aquisição das imagens. Na Figura 4.12 são mostradas duas imagens da classe gergelim, onde a imagem (a) está fora de foco, e a imagem (b) não sofreu este tipo de degradação.




Figura 4.12: Imagens capturadas da classe gergelim (a) e (b).

O método LPQ utiliza a transformada discreta de Fourier (DFT) considerando uma vizinhança ( $m \times m$ ) para representar a textura da imagem. Foi utilizada neste experimento uma janela de  $3 \times 3$  com parâmetro de correlação igual a 1. Essa configuração foi escolhida porque apresentou melhores resultados. A saída do método gerou um vetor com 256 códigos LPQ, que foram utilizados para treinamento de um classificador SVM. O classificador SVM foi treinado com *kernel* QUADRATIC. A Figura 4.13 mostra os histogramas das classes canola, soja e feijão cavalo.

Acompanhando a tendência dos outros descritores, a classe *Soja* apresentou o pior resultado, conforme mostra a Tabela 4.5.

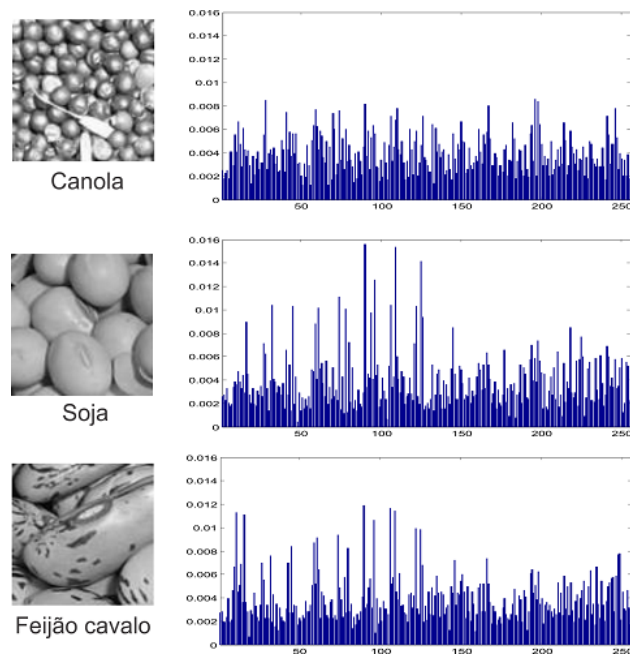


Figura 4.13: Histograma dos códigos LPQ em imagens de canola, soja e feijão cavalo de tamanho 96x96.




Figura 4.14: Comparação entre os descritores de CLBP e LPQ.

#### 4.4.6 Histograma

Histograma é a representação da distribuição da frequência de ocorrência de um conjunto de números. Para uma imagem digital com níveis de cinza o histograma

Tabela 4.5: Resultados obtidos utilizando os códigos LPQ com SVM *kernel* QUADRATIC.

Classe esperada	Classe resultante	Acerto %
Canola	Canola	100,00
Cevada	Cevada	98,33
Cevadinha	Cevadinha	76,67
Ervilha Inteira	Ervilha Inteira	100,00
Ervilha Partida	Ervilha Partida	93,33
Feijão Cavalo	Feijão Cavalo	76,67
Gergelim	Gergelim	100,00
Lentilha	Lentilha	86,67
Linhaça	Linhaça	91,67
Milho	Milho	91,67
Quinoa	Quinoa	100,00
Soja	Soja	25,00
Torta de Algodão	Torta de Algodão	100,00
	Média	87,69
	Desvio padrão	20,63
	Erros	0

representa a frequência dos tons de cinza presentes nesta imagem. O histograma é definido por uma função discreta  $h(r_k) = n^k$ , onde  $r_k$  é o  $k$ -enésimo nível de cinza e  $n^k$  é o número de pixels da imagem com essa intensidade. Com a intenção de analisar características de variação de cor nas imagens obtidas que as tornassem discriminantes entre si, foi extraído o histograma das imagens. Histogramas estreitos indicam imagens com pouco contraste, pois a diferença entre os níveis de cinza é baixa, já uma distribuição uniforme dos níveis de cinza no histograma indica uma imagem com bastante contraste. Essas diferenças podem ser vistas no histograma das imagens mostradas na Figura 4.15, onde uma imagem de gergelim é comparada com uma imagem de feijão cavalo. Gergelim é uma semente pequena, branca e achatada, que se acomoda de maneira uniforme do copo do dispositivo, já o feijão cavalo é uma semente grande, com manchas na superfície e que tem acomodação variada, deixando lacunas entre uma semente e outra, essas lacunas tem um tom de cinza diferente da semente, assim como as manchas no corpo da semente, isso criou

diferenças nos histogramas.

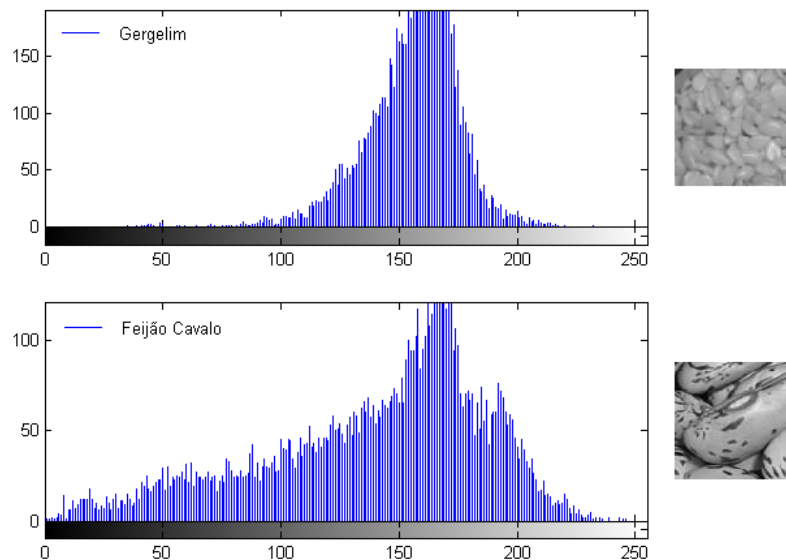


Figura 4.15: Histograma das sementes de gergelim e feijão cavalo.

A saída do histograma gerou um vetor de 256 informações de níveis de cinza, com esse vetor foi treinado um SVM com *kernel* QUADRATIC, os resultados são mostrados na Tabela 4.6.

Dentre os descritores testados, Histograma foi o que apresentou os piores resultados. Assim como Haralick o classificador errou a classe *Cevada*, confundindo-a com *Soja*, demonstrando que a variação nos níveis de cinza destas classes são parecidos. A Figura 4.16 mostra a comparação entre todos os métodos testados individualmente neste trabalho.

De maneira geral todos os descritores obtiveram quase o mesmo desempenho, conforme mostra o gráfico na Figura 4.16, com exceções dos descritores de Haralick e Histograma que apresentaram erros na classe *Cevada*. Outra característica observada no gráfico é que a classe *Soja* apresentou o pior resultado, entre os descritores. Com o objetivo de melhorar os resultados obtidos, combinações entre os descritores

Tabela 4.6: Resultados obtidos utilizando Histograma com SVM *kernel* QUADRA-TIC.

Classe esperada	Classe resultante	Acerto %
Canola	Canola	100,00
Cevada	Soja	0,00
Cevadinha	Cevadinha	96,67
Ervilha Inteira	Ervilha Inteira	68,33
Ervilha Partida	Ervilha Partida	78,33
Feijão Cavalo	Feijão Cavalo	76,67
Gergelim	Gergelim	96,67
Lentilha	Lentilha	95,00
Linhaça	Linhaça	98,33
Milho	Milho	91,67
Quinoa	Quinoa	100,00
Soja	Soja	25,00
Torta de Algodão	Torta de Algodão	92,86
	Média	78,42
	Desvio padrão	31,31
	Erros	1




Figura 4.16: Comparação entre todos os métodos testados individualmente neste trabalho com imagens 192x192 *pixels*.



foram realizadas.

#### 4.4.7 Combinação dos Descritores

Bons resultados foram obtidos testando individualmente os descritores, porém algumas classes, como por exemplo, soja, não obtiveram resultados satisfatórios. Com o objetivo de melhorar o resultado geral da classificação e principalmente desta classe, testes com combinações de descritores foram realizadas. A combinação tem como princípio unir características discriminantes dos descritores, facilitando o aprendizado do classificador e como consequência melhorando o resultado final. Com base nos resultados individuais combinações foram criadas, buscando unir o bom desempenho individual dos descritores em determinadas classes.

A Tabela 4.7 mostra a taxa média de acerto, o desvio padrão e o número de erros do classificador. Com base nesses resultados foram definidas as combinações. No total foram testados os 6 descritores que se fossem combinados entre si resultariam em  $2^n - n - 1$  combinações, ou seja, um total de 57 variações. Para otimizar os testes, foram escolhidos e combinados os 5 melhores descritores da Tabela 4.7 resultando num total de  $2^5 - (5 - 1) = 26$  combinações.

Para testar o descritor Histograma que ficou de fora da primeira combinação, novamente foram escolhidos os 5 melhores resultados combinados e testadas novas combinações com o Histograma. Melhor resultado + Histograma, segundo melhor resultado + Histograma, e assim sucessivamente até o quinto melhor resultado. Gerando mais 5 variações, assim testando todos os descritores.

No total foram testados 37 combinações, mostrados na Tabela 4.8. Também foram analisados os *kernels* QUADRATIC e POLYNOMIAL nos testes, onde

Tabela 4.7: Resultados individual dos descritores ordenados do melhor resultado para o pior.

Classes	Classe Preditada					
	CLBP	LBP	LCP	LPQ	Haralick	Histograma
Canola	100,00	100,00	100,00	100,00	93,33	100,00
Cevada	94,17	96,67	91,67	98,33	0,00	0,00
Cevadinha	96,67	70,00	88,33	76,67	98,33	96,67
Ervilha Inteira	100,00	91,67	100,00	100,00	100,00	68,33
Ervilha Partida	91,67	98,33	90,00	93,33	100,00	78,33
Feijão Cavalo	86,67	78,33	90,00	76,67	86,67	76,67
Gergelim	100,00	100,00	100,00	100,00	100,00	96,67
Lentilha	93,33	91,67	75,00	86,67	100,00	95,00
Linhaça	93,33	85,00	98,33	91,67	90,00	98,33
Milho	98,33	98,33	88,33	91,67	100,00	91,67
Quinoa	100,00	100,00	100,00	100,00	100,00	100,00
Soja	53,33	61,67	21,67	25,00	1,67	25,00
Torta de Algodão	100,00	100,00	100,00	100,00	94,64	92,86
Média	92,88	90,13	87,95	87,69	81,90	78,42
Desvio padrão	12,60	12,76	21,25	20,63	36,24	31,31
Erros	0	0	0	0	1	1

o *kernel* QUADRATIC foi superior e adotado como padrão para os testes de combinações dos descritores.

O melhor resultado ficou com a combinação dos descritores LBP e Haralick, obtendo 94,74% de taxa de acerto e 10,58% de desvio padrão.

## 4.5 SVM Hierárquico

Buscando melhorar os resultados obtidos com a classificação utilizando SVM, foi implementado um modelo de SVM hierárquico, que vem mostrando bons resultados na literatura, como mostrado no trabalho de CHANG et al. (2012). Conforme descrito na seção 3.4 a hierarquia implementada consiste em ordenar as classes por

Tabela 4.8: Resultados geral das combinações testadas.

ID	Combinação de descritores	Média	Desvio padrão	Erros
1	LBP+HARALICK	94,74	10,58	0
2	CLBP	92,88	12,60	0
3	LBP	90,13	12,76	0
4	LBP+LPQ	91,41	15,66	0
5	LBP+LPQ+HARALICK	91,67	17,32	0
6	CLBP+LBP	92,12	17,74	0
7	CLBP+LBP+LPQ	91,99	18,06	0
8	CLBP+LBP+HARALICK	92,82	18,14	0
9	CLBP+LBP+LPQ+HARALICK	92,69	18,53	0
10	LBP+LPQ+HISTOGRAMA	90,83	18,60	0
11	LBP+LCP	90,45	19,44	0
12	CLBP+LPQ	91,60	19,79	0
13	LBP+LPQ+HARALICK+HISTOGRAMA	90,26	19,86	0
14	LBP+LCP+HARALICK	91,09	20,03	0
15	CLBP+HARALICK	92,24	20,48	0
16	LPQ	87,69	20,63	0
17	CLBP+HISTOGRAMA	89,15	21,20	0
18	LCP	87,95	21,25	0
19	LBP+HISTOGRAMA	87,67	21,58	0
20	LBP+LCP+LPQ+HARALICK	90,90	21,71	0
21	LPQ+HARALICK	89,74	21,71	0
22	CLBP+LPQ+HARALICK	91,60	21,72	0
23	LBP+LCP+LPQ	90,64	21,77	0
24	CLBP+LBP+LCP+HARALICK	92,05	21,81	0
25	CLBP+LBP+LCP	92,18	21,83	0
26	CLBP+LBP+LCP+LPQ	91,79	22,24	0
27	CLBP+LBP+LCP+LPQ+HARALICK	92,05	22,26	0
28	LBP+HARALICK+HISTOGRAMA	87,42	22,35	0
29	CLBP+LCP	91,03	22,62	0
30	LCP+HARALICK	89,04	22,68	0
31	CLBP+LCP+HARALICK	91,73	22,73	0
32	CLBP+LCP+LPQ	91,54	23,61	0
33	CLBP+LCP+LPQ+HARALICK	91,92	23,68	0
34	LCP+LPQ	89,29	23,91	0
35	LCP+LPQ+HARALICK	89,55	24,90	0
36	HISTOGRAMA	78,42	31,31	1
37	HARALICK	81,90	36,24	1

ordem de desempenho, as melhores classes são treinadas e testadas primeiro, seguindo até as duas piores classes. Dessa forma o classificador trabalha com um número menor de classes conforme seu desempenho cai. No fim do processo o classificador é treinado apenas com as duas piores classes reduzindo as chances que confundir a imagem de entrada com outras classes. O teste realizado para criar a hierarquia foi feito utilizando um SVM treinado com *kernel* QUADRATIC, o método um-contratodos, sub-imagens 192x192 *pixels* e com a combinação de descritores LBP+Haralick. Ao final do teste as classes foram ordenadas de acordo com seu desempenho, como é mostrado na Tabela 4.9.

Tabela 4.9: Classes ordenadas de acordo com o desempenho obtido na saída do SVM sem hierarquia.

ID	Classes	Acerto %
1	Canola	100,0
2	Ervilha Inteira	100,0
3	Gergelim	100,0
4	Milho	100,0
5	Quinoa	100,0
6	Torta de Algodão	100,0
7	Cevada	98,3
8	Cevadinha	98,3
9	Ervilha Partida	98,3
10	Lentilha	93,3
11	Linhaça	93,3
12	Feijão Cavalo	88,3
13	Soja	61,7

A Tabela 4.10 mostra os resultados obtidos com o método hierárquico, podemos notar uma melhora na classe *Lentilha* que passou de 93,3% para 95,0% no método hierárquico. Já no caso *Linhaça* e *Feijão cavalo* houve uma piora nos resultados, porém ainda essas classes apresentaram resultados iguais ou superiores a 85%. E a classe *Soja* que apresentou o pior resultados em todos os experimentos, nesta metodologia obteve o melhor resultado, indo de 61,7% no SVM sem hierarquia, para 68,3% no SVM hierárquico.

Tabela 4.10: Desempenho das classes obtido na saída do SVM com hierarquia.

ID	Classes	Acerto %
1	Canola	100,0
2	Ervilha Inteira	100,0
3	Gergelim	100,0
4	Milho	100,0
5	Quinoa	100,0
6	Torta de Algodão	100,0
7	Cevada	98,3
8	Cevadinha	98,3
9	Ervilha Partida	98,3
10	Lentilha	95,0
11	Linhaça	85,0
12	Feijão Cavalo	86,7
13	Soja	68,3

O método de avaliação do modelo é a porcentagem de acerto em cada nível da hierarquia, em cada etapa do processo foi contabilizado o número de imagens classificadas e calculado a porcentagem total, no final do processo a classe com maior número de imagens atribuídas é considerada como resposta do sistema.

A Figura 4.17 mostra os resultados obtidos com o sistema hierárquico, avaliados pela porcentagem de acerto das imagens de entrada no sistema. Os testes ocorreram da seguinte maneira: dada uma imagem de entrada, o sistema a transforma em tons de cinza, depois divide esta imagem em sub-imagens, com tamanho de 192x192 *pixels*, então testa as imagens resultantes da divisão num SVM treinado para *Canola* (melhor classe), o resultado do teste é contabilizado e o restante das sub-imagens não classificadas (caso exista) é passado para o próximo SVM, treinado com a classe *Ervilha inteira* (segundo melhor classe), o resultado é contabilizado e o processo continua até que acabem as imagens, ou o sistema chegue ao fim, quando é testando com as duas últimas classes (*Feijão cavalo* e *Soja*).

RESULTADOS	CLASSE ESPERADA													
	Canola	100% (60)												
	Erv. Inteira		100% (60)											
	Gergelim			100% (60)										
	Milho				100% (60)									
	Quinoa					100% (60)								
	T. algodão						100% (60)							
	Cevada							98,3% (59)	1,7% (1)					
	Cevadinha								1,7% (1)	98,3% (59)				
	Erv. Partida									98,3% (59)			1,7% (1)	
	Lentilha										95,0% (57)		5,0% (3)	
	Linhaça										1,7% (1)	85,0% (51)	1,7% (1)	11,7% (7)
	Feijão cavalo											1,7% (1)	86,7% (52)	11,7% (7)
	Soja		25% (15)							1,7% (1)	5,0% (3)			68,3% (41)
	Canola	Erv. Inteira	Gergelim	Milho	Quinoa	T. algodão	Cevada	Cevadinha	Erv. Partida	Lentilha	Linhaça	Feijão cavalo	Soja	
X % - taxa de acerto (X) - número de imagens														

Figura 4.17: Matriz de confusão dos resultados do SVM hierárquico utilizando imagens 192x192 *pixels*.

É possível perceber nos resultados mostrados na matriz de confusão na Figura 4.17, que as classes com piores resultados, foram sempre confundidas com outra classe com características semelhantes, como por exemplo, lentilha e soja, cevada e cevadinha, ervilha inteira e soja. Nesses casos a semelhança de cor, tamanho e forma são bem próximas, isso confundiu o classificador. A classe *Soja* obteve o

pior resultado, com 68,3% de acerto, sendo que 25% foram confundidas com ervilha inteira. Isso se deve a semelhança entre as sementes, como pode ser visto na seção *Conclusão* na Figura 5.1. Soja também foi a classe mais confundida entre as outras classes, das 13 classes avaliadas, 4 foram confundidas com soja.

Outro ponto importante analisado foi que imagens de soja da safra 2013 que foram utilizadas no treinamento dos classificadores, estavam em condições muito ruins, quando comparadas as sementes de soja da safra de 2014, que foram utilizadas nos testes dos classificadores. A figura 4.18 mostra a diferença das safras na classe *Soja*.




Figura 4.18: Diferenças entre as imagens das safras em (a) 2013 e em (b) 2014 .

Visivelmente as sementes da safra de 2013 apresentam estado de conservação muito pior quando comparado as sementes da safra de 2014. Na safra de 2013 as sementes apresentam enrugamento da superfície e manchas, tornando as características extraídas diferentes das obtidas na safra de 2014. Isso aumenta a complexidade para o classificador conseguir discriminar esta classe em relação as outras e a ela mesma, já que entre safras existem diferenças de características.

## 5 Conclusão

É possível observar em todos os descritores que a classe *Soja* apresentou o pior resultado, ou seja, os classificadores não conseguem acertar essa classe. *Soja* também foi muito confundida com *Ervilha inteira* 25%, como mostrado na matriz de confusão na Figura 4.17. Um dos motivos é que as sementes que compõem essas classes são muito parecidas e isso gera a confusão dos classificadores. Mesmo apresentando somente os três melhores resultados é possível observar que para a classe em questão os métodos não conseguem chegar a 70% de acerto, isso gera uma incerteza na classificação das sementes, pois não temos uma alta precisão para esta classe.

No caso específico da *Ervilha Inteira* e da *Soja* a semelhança entre as classes ocorre em tamanho e forma, o que dificultou na extração de características que fossem discriminantes entre ambas as classes. Na figura 5.1 é mostrada a grande semelhança entre as classes *Ervilha Inteira* e *Soja*.




Figura 5.1: Comparação entre as classes Soja (a) e Ervilha inteira (b).

Por outro lado, outras classes tem variações entre seus valores de resultados, a classe *Cevadinha*, por exemplo, com o descritor LBP tem taxa de acerto de 70%, porém tem 98,3% de acerto no descritor Haralick. Isso indica que é melhor utilizar



um descritor em detrimento ao outro. Outra situação foram alguns casos que a taxa de acerto oscila entre 78,3% e 100%, caso da classe *Ervilha Partida*. Esse tipo de situação indicou que as características poderiam ser complementares e funcionaram bem se combinadas. Os resultados obtidos com a combinação de descritores mostrou ser superior em alguns casos, melhorando a classificação.

O tamanho das sub-imagens mostrou ser significativo no resultado da classificação, onde o maior tamanho de sub-imagem apresentou a melhor média da taxa de acerto e o menor desvio padrão. No caso do descritor CLBP a média da taxa de acerto nas imagens de 96x96 *pixels* foi de 82,9% e desvio padrão de 19,86%, contra média de acerto de 92,88% e desvio padrão de 12,6% nas imagens de 192x192 *pixels*.

O método de classificação hierárquica utilizando SVM, também mostrou bons resultados superando o método um-contratodos, porém também apresentou dificuldades na classe de *Soja*. Esse resultado ruim da soja tem como motivo principal o fato das sementes da safra de 2013 serem um pouco diferentes da safra de 2014 como foi visto na Figura 4.18 na seção *Resultados e Discussão*. As sementes de soja da safra de 2013 apresentam um estado de conservação ruim, com rugas na superfície e diferentes colorações nos grãos, diferente das sementes da safra de 2014 que apresentam boas condições. Essa diferença entre as safras tornou mais complexo criar um vetor de características com um padrão para esta classe, sem um padrão bem definido o classificador teve dificuldade em discriminar a classe *Soja* das demais classes, principalmente com a classe *Ervilha inteira*, que tem características muito semelhantes.

De maneira geral o método proposto parece ser promissor, já que 12 das 13 classes apresentaram taxa de acerto igual ou superior a 85%, e também bastante robusto, já que foi testado com sementes de outra safra, onde as mesmas podem sofrer variações de tamanho, cor e forma, devido a muitos motivos, como por exemplo,

transporte, alocação, clima, temperatura, etc.

Como proposta para trabalhos futuros a utilização de cores pode ser uma alternativa para classificar a soja, porém ainda não foi testada. A utilização da média do canal H do modelo HSV pode ser discriminante para essa classe. Uma outra proposta é aumentar a base com imagens de outras safras e/ou classes, pois as safras de 2013 e 2014 possuem outras sementes fotografadas, porém não estão presentes em ambas. Uma nova safra pode aumentar a quantidade de classes.

## Referências

- ARAÚJO, M. J. **Fundamentos de agronegócios**. [S.l.]: Atlas, 2005.
- BARBOSA, D. P. **Avaliação de descritores texturais geoestáticos e de Haralick para o reconhecimento de plantas daninhas**. 2009. Tese (Doutorado em Ciência da Computação) — Universidade Federal de Viçosa, Minas Gerais, Brasil.
- BORTH, M. R. et al. A Visão Computacional no Agronegócio: aplicações e direcionamentos. **7º Encontro Científico de Administração, Economia e Contabilidade (ECAECO)**, [S.l.], 2014.
- BRUMATTI, M. **Redes Neurais Artificiais**. Vitória, Espírito Santo, ca, [S.l.], 2005.
- BURKS, T. et al. Backpropagation neural network design and evaluation for classifying weed species using color image texture. **Transactions of the ASAE**, [S.l.], v.43, n.4, p.1029–1037, 2000.
- CHANG, Y. et al. Fast and efficient lung disease classification using hierarchical one-against-all support vector machine and cost-sensitive feature selection. **Computers in biology and medicine**, [S.l.], v.42, n.12, p.1157–1164, 2012.
- CHTIOUI, Y. et al. Identification of seeds by colour imaging: comparison of discriminant analysis and artificial neural network. **Journal of the Science of Food and Agriculture**, [S.l.], v.71, n.4, p.433–441, 1996.
- FILHO, P. L. P. et al. Forest species recognition using macroscopic images. **Machine Vision and Applications**, [S.l.], 2014.
- GASQUES, J. G. et al. **DESEMPENHO E CRESCIMENTO DO AGRO-NEGÓCIO NO BRASIL**. Brasília, Brasil: IPEA, 2004.

- GUO, Y.; ZHAO, G.; PIETIKÄINEN, M. Texture Classification using a Linear Configuration Model based Descriptor. In: BMVC. **Anais...** [S.l.: s.n.], 2011. p.1–10.
- HANUSIAK, R. K. et al. Identificação da Autoria de Manuscritos com Base em Atributos Genéticos e Genéricos da Escrita. **Revista de Informática Teórica e Aplicada**, [S.l.], v.17, n.2, p.193–209, 2010.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. H. Textural features for image classification. **Systems, Man and Cybernetics, IEEE Transactions on**, [S.l.], n.6, p.610–621, 1973.
- ISO 711. **Cereals and cereal products - Determination of moisture content.** ISO 711:1985.ed. [S.l.]: ISO, 1985. 5p. (711).
- ISO 712. **Cereals and cereal products - Determination of moisture content.** ISO 712:2009.ed. [S.l.]: ISO, 2009. 16p. (712).
- LORENA, A. C.; CARVALHO, A. C. de. Uma introdução às support vector machines. **Revista de Informática Teórica e Aplicada**, [S.l.], v.14, n.2, p.43–67, 2007.
- OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. **Pattern recognition**, [S.l.], v.29, n.1, p.51–59, 1996.
- OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, [S.l.], v.24, n.7, p.971–987, 2002.
- OJANSIVU, V.; HEIKKILÄ, J. Blur insensitive texture classification using local phase quantization. In: **Image and signal processing**. [S.l.]: Springer, 2008. p.236–243.

- OJANSIVU, V.; RAHTU, E.; HEIKKILA, J. Rotation invariant local phase quantization for blur insensitive texture analysis. In: PATTERN RECOGNITION, 2008. ICPR 2008. 19TH INTERNATIONAL CONFERENCE ON. **Anais. . .** [S.l.: s.n.], 2008. p.1–4.
- OLIVEIRA, N. de. **IBGE**: safra de grãos será 2,2% maior que em 2013. Acesso em: 1 mai. 2015.
- ORLANDO, R. C. **Sistema de visão artificial para discriminação entre plantas daninhas e milho**. 2003. Tese (Doutorado em Ciência da Computação) — Universidade Federal de Viçosa, Minas Gerais, Brasil.
- PARK, B.; CHEN, Y. AEautomation and emerging technologies: co-occurrence matrix texture features of multi-spectral images on poultry carcasses. **Journal of agricultural engineering research**, [S.l.], v.78, n.2, p.127–139, 2001.
- QUEIROZ, J. E. R. de; GOMES, H. M. Introdução ao Processamento Digital de Imagens. **RITA**, [S.l.], v.13, n.2, p.11–42, 2006.
- RIBEIRO, S. S. **Extração de características de imagens aplicada à detecção de grão ardidos de milho**. 2015. Tese (Doutorado em Ciência da Computação) — Universidade Estadual de Ponta Grossa, Ponta Grossa, Brasil.
- SHEARER, S. A.; HOLMES, R. et al. Plant identification using color co-occurrence matrices. **Transactions of the ASAE**, [S.l.], v.33, n.6, p.2037–2044, 1990.
- SILVA, A. M. **Curso Processamento digital de imagens de satélite**. Acesso em: 5 mai. 2015.
- SILVA SIMÕES, A. da; COSTA, A. H. R. Classificação de laranjas baseada em padrões visuais. **Anais do Simpósio Brasileiro de Automação Inteligente**, [S.l.], 2003.

- TANG, L. et al. Texture-based weed classification using gabor wavelets and neural network for real-time selective herbicide applications. **Urbana**, [S.l.], v.51, p.61801, 1999.
- YANG, C. et al. Application of artificial neural networks in image recognition and classification of crop and weeds. **Canadian Agricultural Engineering**, [S.l.], v.42, n.3, p.147–152, 2000.